

Universidad Complutense de Madrid

Facultad de Informática



Implementación de técnicas de bajo consumo en WBSN

Autor Álvaro Martín Otero

**Directores de proyecto José Luis Ayala Rodrigo
 Josué Pagán Ortiz**

Trabajo de Fin de Grado

Grado en Ingeniería de Computadores

Junio de 2017

Agradecimientos

Quiero agradecer a mis padres, a mi hermano, a mi tía Rosa y a esa persona especial, que siempre han confiado en mí. Siempre estaré agradecido por ese apoyo incondicional que me habéis brindado, ya que si puedo estar escribiendo esto, es por vosotros.

También agradecer a mi tutor, Josué, por toda la ayuda que me ha ofrecido y todo lo que he aprendido con él.

Resumen

El Internet de las cosas es un paradigma que está revolucionando la manera de interactuar entre las personas y los objetos, dando lugar al manejo de grandes cantidades de información que hay que procesar y que implican un aumento consumo energético en los sistemas y redes de computación que antes no existía, además del impacto ambiental asociado. Esta revolución está afectando a diversos campos, como el de la salud, dando lugar al *eHealth*. Gracias al *eHealth* se puede realizar una monitorización continua mediante una red de sensores corporales a enfermos crónicos para realizar una predicción de las crisis sintomáticas. Este estudio se centra en concreto en la migraña, una enfermedad neurológica que afecta entorno al 15 % de la población europea, y cuyo tratamiento da lugar a elevados costes para la administración pública y entidades sanitarias. La predicción de crisis de migraña requiere de una monitorización ambulatoria continua, que genera grandes cantidades de datos que deben ser enviados a un centro de procesado de datos. El dispositivo mediante el cual se recogen estos datos dispone de batería, por tanto es de importante reducir su consumo para aumentar su autonomía. Este estudio se centrará en el análisis de métodos de compresión basados en la transformada de Wavelet, la transformada de Fourier y Compressed Sensing aplicados a las señales biomédicas que requieren de una alta tasa de muestreo (electrocardiograma y fotopletismografía). Los resultados obtenidos muestran que se reducirán hasta un 93 % el volumen de datos a enviar y así conseguir una mayor vida útil de las baterías.

Abstract

Relation between people and objects faces a revolution due to the paradigm of the Internet of Things. This paradigm leads to the generation of big amounts of information that must be handled, which implies an increase of the energy consumption in the communication networks and computation system unseen few years ago; in addition, there is an environmental impact associated that must be considered as well. This revolution affects several fields such as health that has given rise to the *eHealth*. Thanks to *eHealth* the continuous monitoring of patients suffering from a chronic disease can be carried out through the use of a wireless body sensor network, which opens the opportunity to predict symptomatic crisis of these diseases. This study focuses specifically on migraine, a neurological disease that affects 15 % of the European population, and whose treatment leads to high economic costs for the public and private health systems. The prediction of migraine crises requires a continuous and ambulatory monitorization, which generates large amounts of data that must be sent to a data center. The monitoring device uses batteries, so it is important to reduce the energy consumption to increase its autonomy. This study will focus on the analysis of compression methods based on the Wavelet transform, the Fourier transform and Compressed Sensing techniques applied to biomedical signals that require a high sampling rate (electrocardiogram and photoplethysmography). The results show that the amount of data to be sent can be reduced up to 93 % and thus have a longer battery life.

Índice general

Agradecimientos	3
Resumen	5
Lista de figuras	11
Lista de tablas	13
Acrónimos	15
Palabras clave	17
1. Introducción	19
1.1. eHealth	19
1.2. Caso de estudio: monitorización continua y predicción de crisis de migraña	20
1.3. Motivación y propósito del estudio	21
1.3.1. Objetivos de este proyecto	22
1.3.2. Fases del trabajo	22
2. Introduction	23
2.1. eHealth	23
2.2. Case study: continuous monitoring and prediction of migraine attacks	24
2.3. Study motivation and purpose	24
2.3.1. Objectives of this project	26
2.3.2. Phases of work	26
3. Estado del arte	27
3.1. eHealth en IoT	27
3.2. Migraña en el entorno IoT	28
3.3. WBSNs	29
3.4. Problemas de consumo en WBSN en el entorno IoT	33
4. Metodología	35
4.1. Introducción a la metodología	35
4.1.1. Algoritmos de compresión	36

4.2. Transformada de Wavelet discreta	37
4.2.1. Metodología de optimización usando Wavelet	38
4.3. Transformada de Fourier discreta	38
4.3.1. Metodología de optimización usando DFT	38
4.4. Compressed Sensing	39
4.4.1. Metodología de optimización usando CS	40
5. Fase experimental	41
5.1. Montaje experimental	42
6. Resultados	45
6.1. Métricas	45
6.1.1. Transformada discreta de Wavelet	47
6.1.2. Transformada discreta de Fourier	49
6.1.3. Compressed Sensing	52
6.2. Consumo energético	54
6.2.1. Transformada discreta de Wavelet	55
6.2.2. Transformada discreta de Fourier	56
6.2.3. Compressed Sensing	57
6.2.4. Comparativa de consumos	58
7. Conclusiones	61
8. Futuras Líneas de Investigación	65
Bibliografía	68
Autorización de difusión	69

Índice de figuras

1.1. Ejemplo de topología de una WBSN.	21
2.1. Example of a WBSN topology.	25
3.1. Colocación de los sensores.	30
3.2. Shimmer 3.	31
3.3. BioSignalPlux.	32
3.4. Bitalino.	32
3.5. Dispositivo Ad hoc del equipo GreenDISC con la empresa M2C.	33
4.1. Diagrama de la optimización.	35
5.1. Topología de la WBSN utilizada para la predicción de migrañas.	41
5.2. Diagrama del emisor.	42
5.3. Diagrama del receptor.	42
5.4. Conexión del módulo Bluetooth	43
5.5. Conexión del sensor de corriente.	43
5.6. Montaje completo del dispositivo	44
6.1. Señales ECG y PPG.	45
6.2. Estructura de las señales ECG y PPG.	46
6.3. Componentes de la frecuencia del ECG y PPG.	46
6.4. Coeficientes DWT originales vs coeficientes DWT filtrados.	47
6.5. Reconstrucción de picos.	47
6.6. Porcentaje de datos filtrados respecto al fit	48
6.7. Valores del umbral respecto al fit	48
6.8. Comparación entre el HR original y el $\hat{H}R$ obtenidos con la DWT.	49
6.9. Información sobre el BW del ECG y el PPG.	49
6.10. Señal ECG y PPG reconstruida con DWT.	50
6.11. Porcentaje de ahorro obtenido para cada uno de los BW tras aplicar DFT.	51
6.12. Comparación del fit respecto al BW aplicando DFT	51
6.13. Comparación HR vs $\hat{H}R$ tras aplicar DFT.	52
6.14. Señal ECG y PPG reconstruida tras aplicar CS.	52
6.15. Relación del fit respecto al porcentaje de ahorro aplicando CS.	53

6.16. Valores del <i>fit</i> obtenidos respecto al número de muestras enviadas.	53
6.17. Comparación HR vs $\hat{H}R$	54
6.18. Medida del consumo del <i>baseline</i> para el ECG y el PPG.	55
6.19. Medida del consumo del método de optimización DWT para el ECG y el PPG. . .	56
6.20. Medida del consumo del método de optimización DFT para el ECG y el PPG. . .	57
6.21. Medidas del consumo del método de optimización CS para el ECG y el PPG. . .	58
6.22. Comparación del porcentaje de ahorro.	59

Índice de cuadros

6.1. Medidas de consumo del caso <i>baseline</i> de las señales ECG y PPG para el experimento diseñado.	55
6.2. Medidas de consumo aplicando DWT a la señal ECG y PPG para el experimento diseñado.	56
6.3. Medidas de consumo aplicando DFT a la señal ECG y PPG para el experimento diseñado.	57
6.4. Medidas del consumo aplicando CS a la señal ECG y PPG para el experimento diseñado.	58
6.5. Comparación del consumo de los algoritmos de compresión en el ECG.	58
6.6. Comparación del consumo de los algoritmos de compresión en el PPG.	59

Lista de Acrónimos

AAL Asistencia en las tareas cotidianas

BW Ancho de banda

CPD Centro de procesamiento de datos

CS Compressed Sensing

DFT Transformada discreta de Fourier

DWT Transformada discreta de Wavelet

ECG Electrocardiograma

EDA Actividad electrodérmica

EMG Electromiograma

FW Firmware

HR Ritmo Cardíaco

IDFT Transformada inversa de Fourier discreta

IDWT Transformada discreta de Wavelet inversa

IoT Internet de las cosas

NRMSE Error medio cuadrático normalizado

PPG Fotopletismografía

SNA Sistema nervioso autónomo

SpO₂ Saturación de oxígeno capilar

WBSN Red de sensores corporales inalámbricos

Palabras clave

Palabras clave en Español

- Eficiencia energética
- Internet de las cosas
- eSalud
- Señales biomédicas
- Migraña
- Algoritmos de compresión
- WBSN

Keywords in English

- Energy efficiency
- Internet of things
- eHealth
- Biomedic signals
- Migraine
- Compression algorithms
- WBSN

Capítulo 1

Introducción

1.1. eHealth

El Internet de las cosas (Internet of Things, IoT, por sus siglas en inglés) es una revolución, un paradigma, en las conexiones entre las personas y los objetos, proporcionando en tiempo real una gran cantidad de información. IoT consiste en la interconexión de dispositivos a Internet formando redes de diversa topología (en estrella, redes *mesh*, punto a punto...) donde los dispositivos pueden compartir información entre sí para alcanzar un conocimiento superior del entorno que les rodea. El número de dispositivos siempre conectados ha ido creciendo de manera exponencial en los últimos años y se estima que en el año 2020 habrá más de 50 mil millones de dispositivos conectados¹.

Las aplicaciones para las que se diseñan estas redes son muy heterogéneas; en cada campo de aplicación surgen nuevas necesidades apoyadas por el incremento de la integración de procesadores más rápidos, más pequeños, de menor consumo y más asequibles. Del mismo modo el incremento del número de las infraestructuras de comunicaciones inalámbricas y de interfaces de comunicación de bajo consumo está propiciando la expansión de estos dispositivos siempre conectados.

Uno de los campos que está inmerso en la revolución del IoT es el de la salud. Su uso incluye el diagnóstico remoto, la prevención de riesgos para la salud, el seguimiento y la gestión de enfermos; permitiendo reducir los costes por visitas al médico, y así mejorar la productividad y eficiencia del sistema, así como la calidad de vida de los pacientes. Todo este nuevo conjunto de tecnologías se denomina *eHealth*. *eHealth* facilita la mejora de las estrategias de seguimiento, control y atención de enfermedades crónicas, mediante el uso de dispositivos (generalmente de bajo coste por su distribución masiva y menor precisión que los equipos médicos convencionales) que permiten recopilar información de forma remota, dando lugar a una medicina dirigida y personalizada. Para asistir a los pacientes se utilizan este tipo de dispositivos para poder llevar una retroalimentación constante consiguiendo una medicina más eficaz y preventiva además de reducir su coste.

Por eso, en este Trabajo de Fin de Grado, se desarrolla una metodología de estudio para la reducción de consumo energético y cantidad de datos transmitidos en una red de monitorización de *eHealth*. Se necesita esta eficiencia energética ya que estas aplicaciones requieren de dispositivos

¹<http://www.gigavation.com/?p=156>

portátiles alimentados por baterías que deben funcionar sin descanso. Dada las limitaciones en peso, tamaño y duración de las baterías, la eficiencia energética es indispensable.

1.2. Caso de estudio: monitorización continua y predicción de crisis de migraña

La migraña es una de las enfermedades neurológicas más discapacitantes. Es una enfermedad crónica que afecta entorno al 15 % de la población europea. Se caracteriza principalmente por un dolor de cabeza pulsátil e intenso que habitualmente afecta a un lado de la cabeza, aunque puede extenderse y afectar a ambos. Algunos pacientes asocian unos síntomas previos con el dolor de migraña. Estos síntomas se denominan síntomas prodrómicos, y son tan subjetivos e inespecíficos como: aumento de la frecuencia de bostezo, náuseas, irritabilidad o sensibilidad a factores externos (luz, sonido, contacto físico). Estos síntomas no los sufren todos los pacientes y pueden ocurrir entre 72 y 6 horas antes de que se inicie el dolor. En ocasiones son anteriores o acompañan a síntomas neurológicos transitorios visuales, sensoriales o del habla, y son conocidas como migrañas con aura. Estos síntomas son objetivos y, aunque tampoco los sufren todos los pacientes, suelen ocurrir entre 30 y 5 minutos antes del inicio del dolor. Actualmente los medicamentos no son muy efectivos cuando el dolor ya está muy avanzado, pero se ha demostrado [1] que si se produce la toma de medicamentos antes de que comience el dolor, este se podrá evitar. Esto ha suscitado que haya un gran interés en el estudio de la predicción de las crisis de migraña, con el objetivo de avisar al paciente con antelación a que ocurra el dolor para que pueda tomar el medicamento y poder evitarlo. El objetivo es mejorar la calidad de vida del paciente y reducir los costes asociados por bajas y ausencia o baja productividad en el trabajo y que lleguen hasta los 1200 euros por paciente y año que repercuten en las arcas de las entidades sanitarias públicas y privadas [2].

Recientemente se ha demostrado por miembros del grupo de investigación GreenDISC-Artex de la Universidad Complutense de Madrid que es posible la predicción del dolor en una crisis migrañosa [3].

Esta predicción es posible ya que se producen cambios en algunas variables hemodinámicas controladas por el sistema nervioso autónomo (SNA) cuando ocurre una migraña. El estudio que ha demostrado esto se ha centrado en concreto en: el ritmo cardíaco (Heart Rate, HR, por sus siglas en inglés), la actividad electrodérmica (electrodermal activity, EDA, por sus siglas en inglés), la temperatura superficial de la piel (TEMP) y la saturación de oxígeno capilar periférico (peripheral capillary oxygen saturation, SpO_2 , por sus siglas en inglés).

Gracias al paradigma *eHealth* se puede realizar un seguimiento continuo, ambulatorio y no intrusivo para monitorizar los cambios en las variables hemodinámicas mencionadas y poder prevenir la aparición del dolor con una anticipación de hasta 47 minutos y un promedio de 25 minutos, incluso aunque el paciente no experimente síntomas, mediante una red de sensores corporales inalámbricos de bajo coste (Wireless Body Sensor Network, WBSN, por sus siglas en inglés) [3].

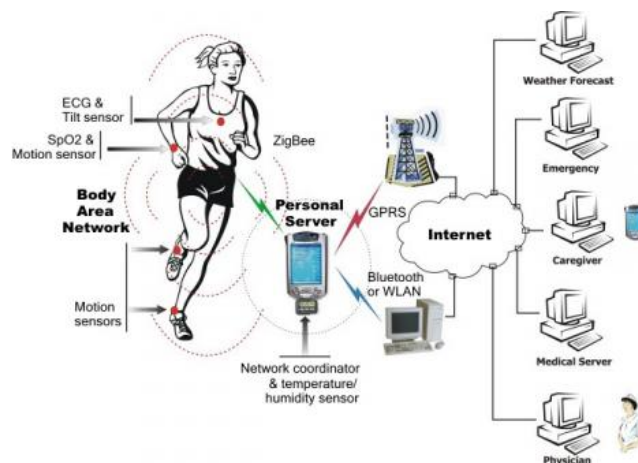


Figura 1.1: Ejemplo de una topología de una WBSN donde se obtienen variables biomédicas del paciente y posteriormente se envían al coordinador y a los CPD ³.

1.3. Motivación y propósito del estudio

Los gastos de estos despliegues implican un gran coste en electricidad, ya que estos CPD son una infraestructura con un alto consumo de energía, además del gasto de todos los nodos que también se despliegan, ya que cada uno dispone de su propia batería. En estos dispositivos la autonomía está siendo uno de los grandes problemas ya que produce grandes limitaciones en su uso, por tanto, hay que tratar de optimizar al máximo el uso de las baterías para poder alargar lo máximo posible su duración.

Este estudio se centrará en la reducción del consumo en los nodos de monitorización en el caso específico de la aplicación para predicción de la migraña, alargando su autonomía y mejorando la experiencia de usuario permitiendo monitorizaciones más largas y continuadas.

Algunos métodos para aumentar esta autonomía pueden ser: reducir el muestreo asumiendo pérdidas de información; utilizar dispositivos con HW específico para la tarea a realizar, con mejores prestaciones pero teniendo un coste económico mayor; o procesar los datos antes de enviarlos teniendo algunas pérdidas de información pero reduciendo la cantidad de datos a enviar.

El método que se utilizará en el estudio es el de procesar los datos antes de enviarlos, para tratar de obtener la información relevante de la señal y únicamente enviar esos valores. Las señales sobre las que se realizarán el estudio y las optimizaciones serán el electrocardiograma (electrocardiography, ECG, por sus siglas en inglés) y el fotopletismograma (photoplethysmogram, PPG, por sus siglas en inglés), debido a que tienen grandes tasas de muestreo. Estas dos variables biomédicas se utilizarán para calcular el HR.

La optimización de este estudio consistirá en tratar de obtener el mayor ahorro de consumo posible reduciendo la cantidad de datos a enviar, suponiendo esto pérdidas de información en la señal. Esto implicará un porcentaje de error en la aplicación para la prevención de la migraña, pero

³Fuente: <http://si.epfl.ch>

siempre será algo asumible que no afecte a su correcto funcionamiento.

En el Capítulo 3 se comentará la situación actual del eHealth en el IoT, profundizando más concretamente en la migraña, además del uso de WBSN para la monitorización. Tras esto se explicará en el Capítulo 4 la metodología seguida y la implementación de los tres algoritmos utilizados, la transformada de Wavelet, la transformada de Fourier y Compressed Sensing, y qué método de optimización tiene cada uno de ellos. A continuación, en el Capítulo 5 se mostrarán los esquemas de experimentación seguidos para realizar este estudio que darán lugar a los resultados que se expondrán en el Capítulo 6. Por último en el Capítulo 7 se mostrarán las conclusiones obtenidas en este trabajo, y en el Capítulo 8 las líneas futuras que se podrían realizar partiendo de este estudio.

1.3.1. Objetivos de este proyecto

- Análisis de diferentes algoritmos de compresión de datos.
- Optimización de la cantidad de datos enviados.
- Estudio de los algoritmos de compresión utilizados en el tratamiento de señales.
- Reconstrucción del HR mediante el ECG y el PPG.
- Análisis de consumo de las técnicas aplicadas.

1.3.2. Fases del trabajo

Con el fin de cumplir los objetivos arriba mencionados, el proyecto se divide en las siguientes fases:

1. Se realizará un estudio de los diferentes algoritmos de compresión y las ventajas y contras de cada uno.
2. Una vez realizado dicho estudio se extraerán métricas y se compararán para cada uno de estos algoritmos.
3. Se realizarán implementaciones de los algoritmos para posteriormente ser utilizados en un dispositivo embebido de bajo coste.
4. Con las implementaciones se realizarán simulaciones del envío de datos para cada una de ellas.
5. Análisis de consumo producido por cada una de las simulaciones realizadas.

Capítulo 2

Introduction

2.1. eHealth

The Internet of Things (IoT) is a revolution, a paradigm, in the connections between people and objects, providing in real time a big amount of information. IoT consists of the interconnection of devices to the Internet leading to many different topologies of networks (star, mesh, point to point...) where the devices can share information to each other to reach a superior knowledge of the environment that surrounds them. The number of connected devices has grown exponentially in recent years and it is estimated that by 2020 there will be more than 50 billion connected devices¹.

The applications for which these networks are designed are very heterogeneous. In each field of application new needs arise supported by the increase of the integration of faster, smaller, and less consuming processors. The expansion of these always-connected devices is also due to the increase of the number of wireless communications infrastructures with low-power communication interfaces.

Health is one of the fields that is immersed in the revolution of the IoT paradigm. Its use includes remote diagnosis, prevention of health risks, monitoring and management of patients. This allows the reduction of costs due to visits to the doctor—improving the productivity and efficiency of the system—as well as the quality of life of patients. This whole new set of technologies is called *eHealth*. *eHealth* helps to the improvement of ambulatory monitoring, control and care of chronic diseases through the use of devices (generally low-cost because of their massive distribution and less accurate than conventional medical equipment) that allow data gathering, visualization and control of patients remotely leading to a targeted and personalized medicine. To assist patients, these devices are used to be able to provide constant feedback, achieving a more effective and preventive medicine in addition to reducing its cost.

In this TFG, a study methodology is developed for the reduction of energy consumption and the amount of data transmitted in an eHealth monitoring network. Energy efficiency is a major

¹<http://www.gigavation.com/?p=156>

concern in these networks as they require portable and battery-powered devices. This is important in an ambulatory device that has weight, size and battery life limitations.

2.2. Case study: continuous monitoring and prediction of migraine attacks

The migraine is one of the most disabling neurological diseases. It is a chronic disease that affects around 15 % of the European population. It is characterized mainly by a pulsating and intense headache that usually affects one side of the head, although it can extend and affect both. Some patients associate previous symptoms with migraine pain. These symptoms are called prodromic symptoms, and they are subjective and non-specific such as increased yawning frequency, queasiness, irritability or sensitivity to external factors (light, sound, physical contact. . .). These symptoms are not experienced by all patients and may occur between 72 and 6 hours before the onset of the pain. Sometimes they appear before or at the same time than some transient neurological visual, sensory or speech symptoms, known as aura. These symptoms are objective and, although not all patients suffer, they usually occur between 30 and 5 minutes before the onset of pain. Currently the medication is not very effective when the pain is already very advanced, but it has been demonstrated [1] that if medication is taken before the pain starts, it can be completely avoided. This has led to the interest in the study of the prediction of migraine attacks, in order to warn patients in advance so that they can take the painkillers and avoid the pain. The objective is to improve the quality of life of the patient and reduce the direct and indirect costs associated with the disease that reach up to 1200 euros per patient per year and leads to high economic costs for public and private health systems [2].

It has recently been demonstrated by members of the GreenDISC-Artex Research Group at the Universidad Complutense de Madrid that the predictive modeling of pain in a migraine crisis is possible [3]. This prediction is possible since there are changes in some hemodynamic variables controlled by the autonomic nervous system (ANS) when a migraine occurs. The study has used four hemodynamic variables: heart rate (HR), electrodermal activity (EDA), surface temperature Skin (TEMP) and peripheral capillary oxygen saturation (SpO_2).

Thanks to the *eHealth* paradigm, continuous ambulatory and non-intrusive monitoring can be performed to monitor changes in the hemodynamic variables mentioned and to be able to prevent the onset of pain with an anticipation of up to 47 minutes and an average of 25 minutes even if the patient does not experience symptoms, through a Wireless Body Sensor Network (WBSN) [3].

2.3. Study motivation and purpose

The deployments of WBSNs lead to high costs in the electricity bill, since data centers are power-hungry infrastructures and the battery of the monitoring devices and coordinator (intermediate devices that might be used or not). In the monitoring devices the autonomy is a big problem

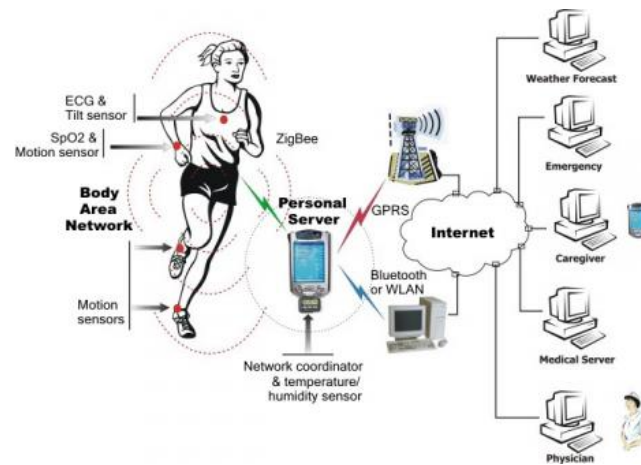


Figura 2.1: Example of a topology of a WBSN where biomedical variables are obtained from the patient and then sent to a coordinator and a data center³.

since it produces limitations in its availability to be used; therefore, it is necessary to optimize the use of batteries in order to extend the maximum its autonomy.

This study will focus on the reduction of consumption in the monitoring nodes in the case study of prediction of migraines, in order to extend the autonomy of monitoring nodes and improving the user experience allowing longer continuous monitorizations.

Some methods to increase this autonomy can be: reduction of the sampling rate—assuming losses of information; use devices with specific HW to improve the performance—having a higher economic cost; or process data before sending them—having some loss of information but reducing the amount of data to send.

The latest method will be used in this study to obtain the more relevant information of the signal and only send that data values. The signals to be studied are: the electrocardiogram (ECG) and the photoplethysmogram (PPG), because they have high sampling rates. These two biomedical variables will be used to calculate HR.

The optimization of this study will be to try to obtain the largest consumption savings possible by reducing the amount of data to be sent, assuming this information losses in the signal. This will imply a percentage error in the application for the prevention of migraine, but it will always be something to assume that does not affect its correct functioning.

The current state of eHealth in IoT will be discussed in Capítulo 3, focusing more specifically on migraine, in addition to the use of WBSN for monitoring. After this the methodology followed and the implementation of the three algorithms used, the Wavelet transform, the Fourier transform and the Compressed Sensing will be explained in the Capítulo 4. The experimental set-up will be shown in the Capítulo 5, leading to the results to be presented in Capítulo 6. Finally, in Capítulo 7 the conclusions are drawn in this paper will be presented, and in Capítulo 8 the future lines that could be made starting from this study.

³Source: <http://si.epfl.ch>

2.3.1. Objectives of this project

- Analysis of different data compression algorithms.
- Optimizing the amount of data sent.
- Study of the compression algorithms used in the treatment of signals.
- Reconstruction of HR through ECG and PPG.
- Analysis of consumption of applied techniques.

2.3.2. Phases of work

In order to tackle the aforementioned objectives, this Thesis is divided into the following phases:

1. A study will be made of the different compression algorithms and the advantages and disadvantages of each one.
2. Once this study is done, metrics will be extracted and compared for each of these algorithms.
3. Implementations of the algorithms will be made for later use in a low cost embedded device.
4. With the implementations will be carried out simulations of the sending of data for each of them.
5. Analysis of consumption produced by each of the simulations performed.

Capítulo 3

Estado del arte

3.1. eHealth en IoT

Como se explicó en el Capítulo 1, eHealth es un campo que está ahora mismo en auge, y que gracias al IoT está viviendo grandes avances. Estos avances van desde drones ambulancia con desfibrilador hasta la monitorización de la salud por las propias personas gracias al crecimiento en la utilización de dispositivos móviles¹.

Esta monitorización permite un diagnóstico precoz, fomentando más la prevención que el tratamiento. Además de facilitar a los profesionales de la salud el acceso a los datos en cualquier momento y su consiguiente análisis, que facilitará un estudio personalizado sobre predicción o prevención de enfermedades. También los pacientes, al ser conscientes de su estado, pueden actuar: desde adaptar sus hábitos para adecuarlos a su patología, hasta la toma preventiva de medicamentos.

Toda la tecnología que soporta *eHealth* se puede utilizar para muchas enfermedades crónicas, como por ejemplo:

Diabetes: Monitorizando los niveles de insulina del paciente, las técnicas actuales permiten controlar en cierta medida el nivel de glucosa de éste. Un ejemplo de dispositivo es GlucoWise².

Parkinson: Aunque por el momento no se puede predecir, sí se puede clasificar de manera objetiva para dar un tratamiento acorde con el nivel de la enfermedad [4].

Epilepsia: Existen diversos estudios [5] que demuestran que mediante el uso de pulseras que miden el EDA y el movimiento se puede detectar cuándo se puede producir una crisis epiléptica. Un dispositivo que realiza esta función es embrace³.

Cuidado de personas mayores: El *eHealth* pretende aumentar el nivel de independencia y bienestar mediante la monitorización utilizando dispositivos con GPS, hogares inteligentes⁴ o dispositivos de control médico.

¹<https://globenewswire.com/news-release/2015/11/18/788256/0/en/eHealth-Market-Will-Reach-308-0-Billion-By-2022-Grand-View-Research-Inc.html>

²<http://www.gluco-wise.com>

³<https://www.empatica.com/product-embrace>

⁴<https://www.ekauri.com>

Cardiopatías: iCardio es un dispositivo que permite realizar electrocardiogramas de manera rápida obteniendo un informe sin necesidad de acudir a un centro sanitario⁵.

Migraña: El presente TFG se centrará en esta neuropatía. A continuación se explicará brevemente en qué consiste el estudio al que este trabajo da soporte.

3.2. Migraña en el entorno IoT

En el Capítulo 1 se introdujo el reto que supone la migraña como enfermedad crónica en el entorno IoT, y su impacto tanto social como económico. En la migraña, el sistema nervioso autónomo regula variables hemodinámicas como la frecuencia cardíaca y respiratoria, la sudoración, o la actividad vasomotora entre otras. Teniendo un registro continuado de este tipo variables (HR, EDA, TEMP Y SpO_2), se puede encontrar una relación entre los cambios en ellas y el dolor de cabeza durante la migraña. En la literatura médica todavía hay dudas y controversias sobre como la disautonomía—trastornos provocados por un mal funcionamiento del sistema nervioso autónomo—se ve afectada en un paciente y si los cambios en estas variables son causa o consecuencia de la fase dolor en la migraña. No obstante, recientes investigaciones han conseguido demostrar mediante un ensayo clínico que se puede conseguir el modelado predictivo del dolor [3], lo que sugiere por estos primeros indicios de que estos cambios son causa del dolor.

En algunas migrañas de algunos pacientes aparecen unos síntomas previos al inicio del dolor. Estos síntomas dan lugar a dos tipos de migraña: migrañas con síntomas prodrómicos y migrañas con aura. Los primeros son síntomas subjetivos e inespecíficos que pueden ocurrir hasta 72 horas antes del inicio del dolor. Estos síntomas pueden ser: náuseas, bostezos, lagrimeo, somnolencia... Éstos son difíciles de discernir del estado de ánimo y la cotidianidad de la vida del paciente, por lo que no son buenos indicadores, ya que tampoco está asegurada la aparición del dolor tras ellos. Los segundos tipos de síntomas son las auras: alteraciones sensoriales que ocurren entre 30 y 5 minutos antes del dolor. Estas alteraciones neurológicas son objetivas y en la mayoría de los casos sí anteceden a un dolor. Las auras más comunes son, en su mayoría, alteraciones visuales: pérdida de la visión de un ojo, visión borrosa, visión de destellos, *etc.*; aunque hay otras como acorchamiento de las extremidades o dificultad de articular palabra. Debido a la farmacocinética de los medicamentos para migraña actuales, los tiempos en los que ocurren estos síntomas son o muy largos, o muy cortos, por lo que definitivamente el paciente acaba sufriendo siempre el dolor de cabeza; tendiendo a la sobremedicación—con los efectos secundarios y económicos que ello conlleva.

Las investigaciones, actuales llevadas a cabo por el grupo de investigación en el que se realiza este TFG, muestran una disautonomía diferente en cada paciente, por lo que se suponen técnicas de modelado por paciente [3], lo que daría lugar a una medicina personalizada y dirigida que sólo es factible en un entorno de eHealth. Para realizar una predicción objetiva, se realiza una monitorización continua de las variables biométricas anteriormente mencionadas. Una de las mayores dificultades del estudio de monitorización mediante WBSN se debe a los cambios hemodinámicos

⁵<https://eurecat.org/es/icardio>

que pueden ocurrir antes, durante y después de la migraña. Para ello, los pacientes que participan en el estudio clínico se monitorizan idealmente durante 24 horas al día en un estudio que suele durar entre 4 y 6 semanas [3], con el fin de capturar alrededor de 5-10 episodios de migraña por cada paciente, para poder obtener más de un modelo por cada uno. Los modelos desarrollados correlacionarán los cambios en las variables de entrada (las variables hemodinámicas) con los cambios en una variable de salida, en este caso la curva sintomática.

En el estudio de predicción de crisis de migraña la WBSN implementada recibe los datos en tiempo real y después se van enviando a un coordinador de manera inalámbrica. Un coordinador es un sistema de computación con un rendimiento superior que puede realizar él mismo las predicciones o enviar los datos a la nube y calcularlas allí. Los sensores que se conectarán a este nodo son el de ECG, EDA, PPG, SpO_2 y TEMP. El SpO_2 y el PPG se obtienen del mismo sensor optoelectrónico y, a pesar de no usarse en el estudio, se recoge porque es una de las señales con las que se realiza el cálculo del SpO_2 . El ECG únicamente se utiliza para calcular el HR por tanto podría eliminarse y usar para ello el PPG, ahorrando batería por adquisición de muestreo (el ECG tiene una tasa de muestreo mayor), envío y procesamiento de datos.

El paciente llevará la WBSN durante el día sin cambiar su vida diaria, pero si sufre migrañas cuando duerme también se realizará la monitorización por la noche. La monitorización es ambulatoria y no invasiva, por lo que el paciente puede realizar su vida de forma normal. Para realizar el estudio se entrena al paciente cómo y dónde se deben colocar los sensores. Si se requiere para alguna actividad, como ciertos deportes, se puede detener el proceso de monitoreo. Los pacientes deben evitar cualquier ingesta de drogas, siendo crucial para no alterar la respuesta corporal antes y durante una crisis de migraña. Si el dolor producido es fuerte se permitirá al paciente tomar medicamentos. En estos casos también se recogen las variables hemodinámicas y el dolor, a pesar de desconocer cuándo terminaría el dolor sin el efecto de la medicación, ya que acelerarán el extremo. Cada episodio de migraña tiene una duración diferente. Para el proceso de modelado no solo se utilizan los datos una vez haya empezado el dolor debido a una crisis de migraña, también se analizan los datos recibidos horas antes de que el paciente indique el inicio.

3.3. WBSNs

Debido a los grandes avances tecnológicos que se están produciendo en la industria de los microcontroladores de alto rendimiento y los nuevos protocolos de comunicación se ha generado un gran interés en las WBSN [6]. Estas redes de sensores permiten que las señales fisiológicas sean fácilmente monitoreadas. Los sensores se colocan en el cuerpo en diversas zonas según las variables biomédicas que se quieran medir.



(a) El sensor ECG se coloca en el pecho en primera derivación. (b) El sensor PPG se pondrá en cualquier dedo (excepto los pulgares).

(c) El sensor de EDA se coloca en el brazo, cerca de la axila. (d) El sensor de temperatura se encuentra cerca de la axila.

Figura 3.1: Colocación de los sensores para monitorización de variables biomédicas en el estudio de predicción de crisis de migraña.

Actualmente se puede realizar monitorización de señales con dispositivos económicos y más asequibles que los equipos médicos convencionales, permitiendo—con calidades de señal suficiente para los propósitos a los que se destinan estas redes de sensores corporales—que cualquier persona pueda llevar un seguimiento de sus variables biomédicas; bien sea por un control de salud o cuando se está realizando ejercicio físico o actividades cotidianas (Ambient Assisted Living, AAL, por sus siglas en inglés). A continuación se muestran algunos de estos dispositivos de bajo coste, con precisión limitada, que permiten una monitorización continua:

Smartphone: Hoy en día casi cualquier persona lleva siempre un smartphone consigo, y esto ofrece un gran abanico de posibilidades en la monitorización mediante WBSN. Cada vez se desarrollan más aplicaciones para facilitar la monitorización de los datos del usuario en diversos ámbitos. Esto se puede utilizar en ámbito médico, Migraine Buddy ⁶ para migrañas

⁶<http://www.migrainebuddy.com/>

entre otras, para visualizar las variables biomédicas cuando realizamos deporte o simplemente para AAL. Los *smartphones* ya tienen una gran capacidad de cómputo, por tanto, también pueden ser utilizados para recibir información recopilada de sensores o dispositivos médicos y analizar dichos datos o transmitirlos mediante cualquiera de sus interfaces inalámbricas a un CPD donde almacenarlos o realizar allí los cálculos.

Smartwatch y smartband: Son pulseras que incluyen típicamente un pulsómetro óptico, acelerómetro, giroscopo y sensor de luz entre otros. Gracias a estos sensores pueden calcular el HR aproximado, ofrecer la función de podómetro y realizar un seguimiento de la calidad del sueño. Se pueden conectar con un *smartphone* mediante Bluetooth. Su uso más extendido es en el *feedback* o seguimiento del estado físico en la realización de actividad deportiva.

Existen también dispositivos más especializados, orientados para la investigación clínica y tecnológica que están preparados para conectar sensores y algunos permite poder programarlos ya que disponen de código abierto. También ofrecen una mayor versatilidad y modularidad. Su uso se puede extender a una mayor cantidad de aplicaciones que los mencionados anteriormente. Algunos ejemplos de estos dispositivos son:

Shimmer: Es un dispositivo portátil formado por sensores, que pueden utilizarse para monitorizar señales biomédicas. Las versiones que comercializan incluyen sensores de ECG, de electromiograma (electromyogram, EMG, por sus siglas en inglés), acelerómetros, giroscopos, de PPG y EDA. El dispositivo puede conectarse mediante Bluetooth para transmitir los datos. Este dispositivo tiene un sistema operativo llamado TinyOs, que se programa en el lenguaje NesC. Hay varias versiones de este dispositivo, siendo la más moderna Shimmer 3. Precio entorno 500€⁷.



Figura 3.2: Shimmer 3.

Plux BioSignal: Dispone de 8 canales para recoger datos de sensores. El dispositivo se ofrece con 4 sensores incluidos. Estos serán a elección del comprador entre estos 9: sensor para EMG, sensor para EEG, sensor de EDA, acelerómetro, sensor de respiración, sensor de fuerza, sensor de temperatura, sensor de luz y sensor para el ECG. También incluye una interfaz

⁷<http://www.shimmersensing.com/products/>

Bluetooth de clase 2 obteniendo un alcance máximo de entre 5 y 10 metros. Precio 995€ y si se desea memoria interna tendría un incremento de 399€⁸




Figura 3.3: BioSignalPlux.

Bitalino: El dispositivo se adquiere con la placa al descubierto (sin carcasa) e incluye sensor de EMG, de ECG, de EDA, de EEG, de luz y un acelerómetro. Está orientado al prototipado. Dispone de una interfaz de programación de aplicaciones (application programming interface, API, por sus siglas en inglés) que permite ser programado con Python y Java entre otros lenguajes. Soporta tanto entradas analógicas como digitales. Precio 149€⁹




Figura 3.4: Bitalino.

A pesar de disponer de estos dispositivos en el mercado, no ha sido posible utilizarlos para el estudio de migrañas. En algunos los sensores disponibles no eran suficientes o resultaba costoso obtener recambios y, debido a que es un dispositivo para monitorizar las señales durante todo el día, hay que tener en cuenta la posibilidad de tener que reemplazarlos a causa de que se rompan por el uso. Otro problema era el HW, que no disponía de la capacidad de cómputo para ejecutar la aplicación, las conexiones Bluetooth eran muy inestables y la batería no era suficiente para el uso que se le pretendía dar. Y por último el SW, la mayoría utilizan sistemas propietarios que no permiten realizar modificaciones, pudiendo únicamente utilizarlo para la tarea que fue diseñado. Estos motivos fueron los que provocaron la necesidad de diseñar un nuevo dispositivo para utilizarlo en la predicción de migrañas:

⁸<https://store.plux.info/kits/215-biosignals-explorer-820201001.html>

⁹<https://store.plux.info/kits/33-bitalino-revolution-board-bt-810121001.html>

Dispositivo *ad hoc*: Dispositivo desarrollado por grupo de investigación GreenDISC de la Facultad de Informática de la UCM en colaboración con la empresa M2C¹⁰, que registra diversas variables como el ECG, el EEG, la EDA, el PPG, la TEMP, el ritmo respiratorio y dispone de acelerómetro y giróscopo. Es capaz de almacenar y enviar los datos mediante una red móvil GSM a un servidor permitiendo tener los datos en tiempo real, si es necesario. Si no se dispone de ancho de banda suficiente para transmitir los datos adquiridos, el dispositivo dispone de una memoria SD en la que poder almacenar los datos. Antes de ser enviados éstos se pueden tratar. El estudio realizado en este TFG será implementado en este dispositivo junto a la aplicación de predicción de migrañas. Precio del nodo 67€(sin sensores).



Figura 3.5: Dispositivo Ad hoc del equipo GreenDISC con la empresa M2C.

3.4. Problemas de consumo en WBSN en el entorno IoT

En este tipo de redes cada nodo obtiene la energía mediante baterías, siendo limitada la cantidad disponible. Por tanto el mayor problema a la hora de implementar aplicaciones en estos dispositivos es la escasez de energía. A la hora de empezar un proyecto se deben tener en cuenta varios factores, como el tipo de sensores necesarios, su coste, la localización específica de alguno de ellos y la robustez, ya que estos deben estar pensados para que un paciente los pueda llevar en su vida diaria.

Para tratar de mejorar la autonomía se pueden extraer las principales características de las señales recibidas y enviar únicamente estas métricas en lugar de enviar los datos continuos. La transformada de Wavelet es utilizada para realizar algoritmos de compresión de datos en el nodo antes de ser enviados. Se han realizado estudios [7] aplicando la transformada de Wavelet a la señal ECG para optimizar la señal y realizar la implementación en una plataforma de sensores portátiles comercial, llamada Shimmer. Como resultado se consiguió una mayor duración de la batería del nodo. Otra técnica utilizada es Compressed Sensing, que permite reducir en gran cantidad el muestreo con tasas de errores muy bajas aumentando así la tasa de datos y la autonomía. Hay estudios realizados [8] que muestran que se puede aplicar con éxito este método a la señal HR, ya que es escasa en el dominio del tiempo, lo que significa que lleva gran cantidad de datos redundantes y por lo tanto pueden ser comprimidas.

¹⁰<http://www.m2csolutions.com/>

Capítulo 4

Metodología

4.1. Introducción a la metodología

En este capítulo se mostrarán las técnicas que se utilizarán para realizar la optimización de los datos a enviar y tratar de mejorar los problemas de consumo explicados en el Capítulo 3.

Para abordar el objetivo del TFG se realizará en primer lugar un estudio offline de la optimización de los parámetros de cada uno de los algoritmos a estudiar, que darán lugar a métricas de calidad con la que se seleccionará un escenario en concreto que dará lugar, en una segunda fase, a una implementación online de los algoritmos para la medición del consumo de cada una de las implementaciones. En esta fase offline se utilizarán previamente obtenidas de un paciente, a diferencia de la implementación online, que se recibirán los datos en tiempo real.

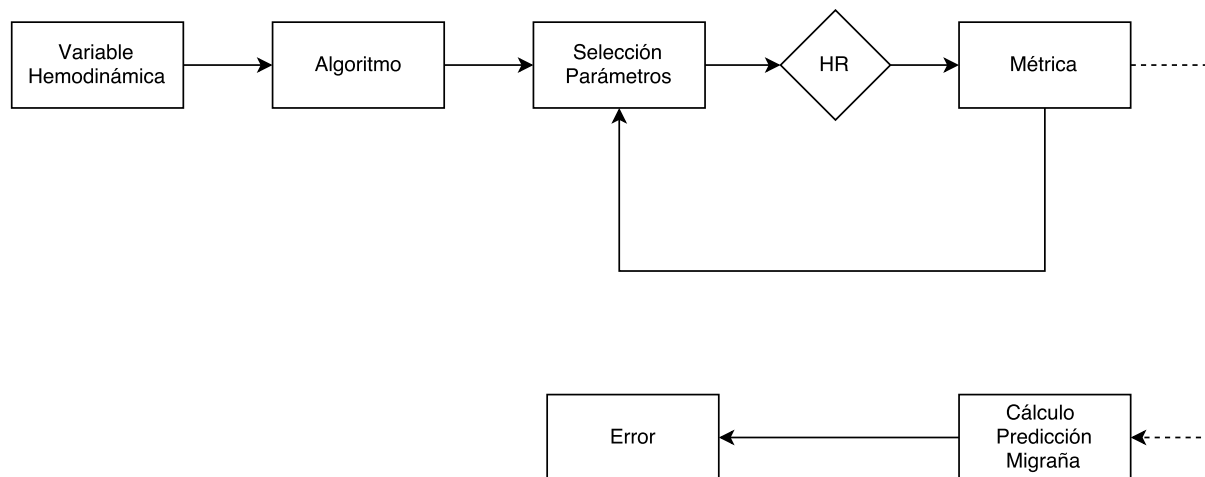


Figura 4.1: Diagrama que muestra el esquema de optimización utilizado para realizar el estudio offline de la optimización de los parámetros.

La Figura 4.1 muestra el esquema de optimización mono-objetivo que se seguirá para el cálculo de parámetros de los algoritmos. Se realizará una optimización heurística en un bucle de optimización. Los resultados de optimización podrían ser locales, pero la búsqueda exhaustiva de convergencia a un resultado global debería abordarse con técnicas avanzadas como la programa-

ción genética, pero que quedan fuera del alcance de este trabajo.

Para el estudio se utilizará una señal hemodinámica (ECG o PPG), previamente obtenida de un paciente, y de las que se extrae la señal HR de referencia. Sobre la señal homodinámica se aplicará uno de los tres algoritmos que se explicarán más adelante. Una vez aplicado el algoritmo correspondiente se realizará una optimización para reducir la cantidad de datos. Para ello se seleccionará un valor inicial a los parámetros con los cuales se aplicará el bucle de optimización, variando estos parámetros en cada iteración.

Para cada uno de estos valores se reconstruirá la señal original—ECG o PPG—y se obtendrá el HR reconstruido. El algoritmo para el cálculo de HR utilizado ha sido desarrollado por el grupo de investigación GreenDISC. Funciona mediante la detección de picos en la señal y mide el tiempo entre ellos utilizando ventanas de 20 segundos con solapamiento de 10. El algoritmo tiene varios parámetros de ajuste de los que no se hablará pues no es el objetivo de este trabajo. En algunas ocasiones algunos picos no son detectados o encuentra falsos picos. Para evitar esto existen algunos algoritmos que permiten detectar cuando se producen estos fallos [9] [10]. Implementando estas técnicas se podrían obtener valores de similitud más elevados al comparar las señales.

La métrica objetivo es el *fit* definido en la Ecuación 4.1, que se expresará en porcentaje de calidad representando el grado de parecido que hay entre dos conjuntos de datos. Se calcula mediante el error cuadrático medio normalizado (Normalized Root Mean Square Error, NRMSE, por sus siglas en inglés). Se tratará de reducir al máximo el número de datos a enviar, para reducir el consumo energético por transmisión, pero siempre teniendo en cuenta la precisión que se necesita para la predicción de migrañas.

Una vez terminado el bucle, tras comprobar todos los valores de los parámetros, se elegirá el más adecuado para ser utilizado en la implementación y se obtendrán los valores que se utilizarán en la implementación. Estos valores pueden ser variables o *look-up table*, este último consiste en una matriz o vector de búsqueda almacenada previamente en la ROM del nodo final evitando una rutina para generar los valores y por tanto ahorrando tiempo de procesamiento.

$$fit = 100 \cdot (1 - NRMSE) \quad (4.1)$$

$$NRMSE = \frac{||x - \hat{x}||}{||x - \bar{x}||} \quad (4.2)$$

Donde x es la señal original, \hat{x} es la señal reconstruida y \bar{x} es la media aritmética de los valores de x .

4.1.1. Algoritmos de compresión

Tres algoritmos van a ser estudiados. Se trata de algoritmos bien conocidos en el estado del arte: en la Sección 4.2 se explicará en que consiste la transformada de Wavelet, en la Sección 4.3 la Transformada de Fourier y en la Sección 4.4 se explicarán los algoritmos de Compressed Sensing (CS).

Las técnicas de CS, son técnicas clásicas de compresión con pérdidas, mientras que Wavelet y la DFT son transformaciones a otros dominios y no tienen pérdidas. No obstante, se llevará a cabo una compresión de señal en los dominios transformados, eliminando en cada caso las componentes transformadas con información menos relevante. Se trata pues, en nuestro caso, de transformaciones vistas como compresiones con pérdidas. En cada sección se mostrará qué parámetros son modificados en el bucle de optimización y qué criterios se han seleccionado para reducir la cantidad de datos a enviar.

4.2. Transformada de Wavelet discreta

La transformada de Wavelet de una función $f(x)$ es la descomposición de $f(x)$ en un conjunto de funciones $\Psi_{s,\tau}(x)$ que forman una base, y son las llamadas “Wavelets”. Las Wavelets son generadas a partir de la traslación y cambio de escala de una misma función wavelet Ψ_x , llamada la “Wavelet madre”, y se define como:

$$\psi_{s,\tau}(x) = \frac{1}{\sqrt{s}} \Psi \frac{x - \tau}{s} \quad (4.3)$$

siendo s el factor de escala y τ el factor de traslación.

En concreto se utilizará la Transformada discreta de Wavelet (Discrete wavelet transform, DWT, por sus siglas en inglés) que es igual que el resto de Wavelet con la diferencia de que debe ser discretamente muestreada [11]. La DWT se define como:

$$W_\psi(j, k) = \frac{1}{\sqrt{M}} \sum_k f(x) \psi_{j,k}(x) \quad (4.4)$$

La DWT es un proceso reversible, y se puede reconstruir mediante la DWT inversa (IDWT):

$$f(x) = \frac{1}{\sqrt{M}} \sum_k W_\varphi(j_0, k) \varphi_{j_0,k}(x) + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_\psi(j, k) \psi_{j,k}(x). \quad (4.5)$$

donde $f(x)$, $\varphi_{j_0,k}(x)$ y $\psi_{j,k}$ son funciones de la variable discreta $x = 0, 1, 2, \dots, M - 1$.

Existen diferentes familias de wavelets, de las cuales no existe un criterio definido para evaluar su calidad, ya que depende de la aplicación. Las más conocidas son: Haar, Daubechies, Symlets, Biortogonal y Shannon. Después de unas primeras pruebas se decidió usar la familia Biortogonal. Tras aplicar la transformada se separan los parámetros según su nivel de energía, estando en A los coeficientes de mayor energía, y en D los de menor. A y D se definen como coeficientes de aproximación y coeficientes de detalle. Se puede observar que la primera parte de la Ecuación 4.5 se corresponde con los coeficientes A y la segunda con los coeficientes D .

La transformada de Wavelet tiene un gran número de aplicaciones en ciencias e ingenierías como la codificación de señales, procesamiento de imágenes o en comunicaciones digitales.

4.2.1. Metodología de optimización usando Wavelet

Se aplica DWT a la señal produciendo un muestreo reducido separando en dos los coeficientes, A el filtro a paso bajo y D el filtro a paso alto. Para comprimir los datos se ha utilizado un umbral para seleccionar los coeficientes que tengan un mayor nivel de energía, siendo todos los valores de D omitidos y únicamente se seleccionan algunos valores de A .

Utilizando únicamente esos valores filtrados por el umbral no se puede reconstruir la señal original, pero sí podemos conseguir los puntos donde hay una mayor cantidad de energía además de la posición en la que estaban, pudiendo así calcular el HR con un gran *fit* respecto al HR obtenido con la señal original a pesar de no disponer de la señal original completa.

Aunque el proceso de DWT es reversible (sin pérdidas), al aplicar estos umbrales a la señal, la reconstrucción será con perdidas, implicando esto un error al calcular el HR.

4.3. Transformada de Fourier discreta

La Transformada de Fourier es una transformada utilizada para extraer la información de dominio frecuencial de señales en el dominio temporal, siendo este proceso reversible. Este cambio de dominio al de la frecuencia nos permite obtener información que no es evidente en el espacio temporal, como por ejemplo saber en qué ancho de banda (Band Width, BW, por sus siglas en inglés) se concentra la energía de una señal y su distribución. La señal en el dominio transformado es una señal compleja que tiene parte real (amplitud) y parte imaginaria (fase). Su uso está muy extendido en el área de las telecomunicaciones y el procesamiento de señal, como el procesamiento de señales acústicas, o el tratamiento de imágenes.

En este estudio se utilizará la transformada discreta de Fourier (Discrete Fourier Transform, DFT, por sus siglas en inglés). La DFT requiere que la función de entrada sea una secuencia discreta de duración finita, como es en nuestro caso con las señales ECG y PPG.

La fórmula de la DFT es:

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-i \frac{2\pi}{N} kn} \quad k = 0, \dots, N-1 \quad (4.6)$$

Y la DFT inversa (IDFT):

$$x[n] = \frac{1}{N} \sum_{k=0}^{N-1} X[k] e^{i \frac{2\pi}{N} kn} \quad n = 0, \dots, N-1 \quad (4.7)$$

Donde $x[n]$ es la señal en el dominio temporal (ECG o PPG) y $X[k]$ representa a ésta en el dominio transformado. N es la longitud total de la señal en muestras y k representa cada uno de los coeficientes espectrales de la DFT.

4.3.1. Metodología de optimización usando DFT

Como se ha explicado, al aplicar la DFT se pueden obtener los datos en el dominio de la frecuencia, pudiendo ver en qué rangos de frecuencia se haya la mayor parte de la energía de la señal.

Una vez aplicado el algoritmo se realiza el estudio para observar dónde se encuentran estas zonas de más energía. Se busca la zona del espectro que aporte mas información (mejor *fit*) en la reconstrucción con pérdidas, para ello se realiza un doble bucle donde se va variando la anchura de un filtro paso banda ideal con ancho de banda BW que se va moviendo a su vez por el espectro de la señal. Una vez la señal ha sido filtrada, tras su reconstrucción—mediante IDFT con pérdidas—se obtiene la señal $\hat{H}R$ y se calcula la métrica de optimización, el *fit*. Éste se calcula con la señal original HR original (calculado de la señal de ECG o PPG sin filtrar) como referencia y el $\hat{H}R$ obteniendo de la señal filtrada. Las componentes frecuenciales que se encuentren dentro del filtro aplicado serán las que habrá que enviar y el resto se podrán omitir ya que no contienen información suficientemente relevante para reconstruir la señal original. Siendo el proceso de DFT reversible, al reducir el BW en la señal la reconstrucción será con pérdidas, implicando esto un error al calcular el HR.

4.4. Compressed Sensing

La teoría de Compressed Sensing establece que una señal x puede ser recuperada con pérdidas mínimas de información submuestreándola a una tasa $m \ll n_{Nyq}$ y bajo condiciones de poca densidad e incoherencia, donde n_{Nyq} representa la frecuencia de muestreo de Nyquist (el doble de la frecuencia máxima de la señal). Esta violación del principio de muestreo de Nyquist ha sido una revolución en el área del procesado de señal y las comunicaciones.

Las técnicas de CS son eficientes cuando se aplican sobre señales periódicas (como nuestras señales de ECG y PPG). Cuando se representan mediante las bases apropiadas en un dominio diferente, muchas señales dan lugar a una representación dispersa o *sparse*, que tiene pocos coeficientes c que sean distintos de cero. A continuación se expone como se aplica esta técnica de compresión:

Dada x una señal muestreada a una tasa de Nyquist n , y c un conjunto *sparse* de coeficientes (la mayoría de ellos igual a cero), la señal x puede escribirse como señala la Ecuación 4.8:

$$x = \Psi c, \quad (4.8)$$

lo que significa que x es una combinación lineal de funciones base representadas por Ψ . En nuestro caso x es un segmento de 1D de la señal ECG o PPG de longitud p , y $\Psi \in \mathbb{R}^{p \times p}$ es una matriz de Transformación Discreta de Coseno (DCT). La longitud de c es igual a p .

Para representar la señal submuestreada y , se usa la matriz Φ . Φ es la matriz *sensing* y toma q muestras aleatorias de la señal x , así:

$$y = \Phi x \quad (4.9)$$

En nuestro caso, la señal y es el dato que se envía desde el dispositivo de monitorización al coordinador o CPD, y su longitud es $q \times 1$; donde $\Phi \in \mathbb{R}^{q \times p}$. Observe que $q/p = m/n$, a lo que se llama la ratio de compresión *cr*.

Para obtener una aproximación x' de la señal original x en el coordinador, se requiere la estimación de los coeficientes c . Usando las Ecuaciones 4.8 y 4.9, también podemos escribir la

señal comprimida y como Ecuación 4.10:

$$y = \Phi \Psi c = Ac, \quad (4.10)$$

donde $A \in \mathbb{R}^{q \times p}$ es la matriz *measurement*, definida en la Ecuación 4.11. A es la extracción de q filas de la matriz DCT Ψ , y el nodo emisor y el receptor la conocen para calcular la estimación c' de los coeficientes c . Así, la señal reconstruida $x' = \Psi c' \approx x$.

$$A = \Phi \Psi \quad (4.11)$$

El cálculo de los coeficientes de c' es costoso y se tiene que realizar en servidores con mayor rendimiento computacional del que disponen los dispositivos de monitorización. Según los autores que llevaron las técnicas de detección de compresión a su estado actual, cada columna de la matriz A implica resolver un sistema lineal. Este es un sistema lineal indeterminado y es difícil de resolver [12]. Por lo tanto, el problema necesita ser transformado a l_1 - *norm* para resolver:

$$\min_{c'} \|c'\| \quad \text{s.t.} \quad \|y - Ac'\| < \epsilon, \quad (4.12)$$

donde ϵ es el error de reconstrucción. c' se puede encontrar en tiempo polinómico usando programación lineal.

4.4.1. Metodología de optimización usando CS

En este bucle de optimización se varía el ratio de compresión, cr , buscando el menor valor posible en el que poder realizar una reconstrucción fiable. Al reducir cr , se reduce el tamaño de la matriz *sensing*. Esta componente de la matriz la llamaremos q . Una vez fijado el cr , en la implementación se debe realizar la operación de matrices entre la matriz *sensing* y los valores de entrada de la señal, x . Para realizar la reconstrucción únicamente se necesita enviar el vector obtenido del cálculo, y , ya que el ratio de compresión es fijo y conocido por ambos extremos de la comunicación. Como la matriz *sensing* se obtiene previamente, el valor lo tienen tanto el nodo para realizar el cálculo, como el servidor para poder realizar la reconstrucción. En la sección anterior se dijo que para generar la matriz *sensing* se toman q muestras aleatorias, pero en nuestro caso es pseudo-aleatoria, ya que solo lo calculamos una vez y lo utilizaremos como *look-up table* en la implementación, en lugar de obtenerlo con cada vector que llega.

Capítulo 5

Fase experimental

Una vez obtenidas las métricas y las *look-up table*, que contienen los parámetros de cada algoritmo para ser almacenados en el equipo de monitorización, como se explicó en el Capítulo 4, lo siguiente es realizar una implementación en un dispositivo real de monitorización para poder calcular cada uno de los consumos utilizando los diferentes algoritmos.

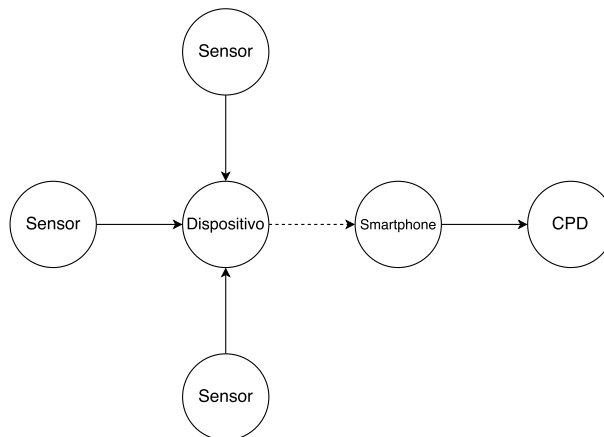


Figura 5.1: Topología de la WBSN utilizada para la predicción de migrañas. El nodo *Dispositivo* realiza la compresión de las señales recibidas de los sensores y las envía al CPD.

La Figura 5.1 muestra la topología de red que utilizará la WBSN utilizada para la predicción de migrañas. El dispositivo está conectado con los sensores mediante una red en estrella y se conectará con el *smartphone* y el CPD mediante una red punto a punto. Este nodo será el encargado de recibir las señales de los sensores que estarán conectados a él y comprimirlas. Los datos una vez hayan sido comprimidos serán enviados a un *smartphone* mediante Bluetooth o directamente al CPD a través de una red móvil. La línea entre el dispositivo y el *smartphone* se ha representado como discontinua debido a que no siempre se enviarán los datos al *smartphone* para que los reenvíe al CPD, ya que como se indicó antes, el dispositivo tiene la posibilidad de enviar los datos directamente mediante red móvil.




Figura 5.2: Diagrama del emisor, que recibe los datos procedentes de los sensores conectados a él, los almacena en un buffer, les aplica la transformada y los envía al coordinador o al CPD.

En la Figura 5.2 se muestra el esquema del emisor, que será el encargado de almacenar temporalmente la señal recibida por alguno de los sensores en un buffer, transformar los datos como se explicó en el Capítulo 4, y por último enviarlos al coordinador o al CPD.




Figura 5.3: Diagrama del receptor, recibe los datos y los va almacenando en un buffer, para después aplicarle la transformada inversa y procesarlos.

El receptor será como se muestra en la Figura 5.3. Almacenará la información recibida en un buffer para, posteriormente, recuperar la información revirtiendo el proceso de transformación realizado en el nodo y por último procesando los datos. Este proceso se realizará en el CPD.

5.1. Montaje experimental

Debido a motivos de disponibilidad no ha sido posible realizar el estudio sobre el dispositivo *ad hoc* desarrollado por el grupo GreenDISC mostrado en el Capítulo 3, pero el estudio es extrapolable a ese nodo y será implementado para futuras monitorizaciones. Por tanto el dispositivo que simulará la tarea de nodo será un Arduino UNO¹, en el cual se le cargará previamente la implementación y se le conectará un módulo Bluetooth que realizará el envío de los datos procesados. En concreto será un módulo Bluetooth genérico—el módulo *Mate Silver* de *Sparkfun*².

¹<https://www.arduino.cc/>

²<https://www.sparkfun.com/>

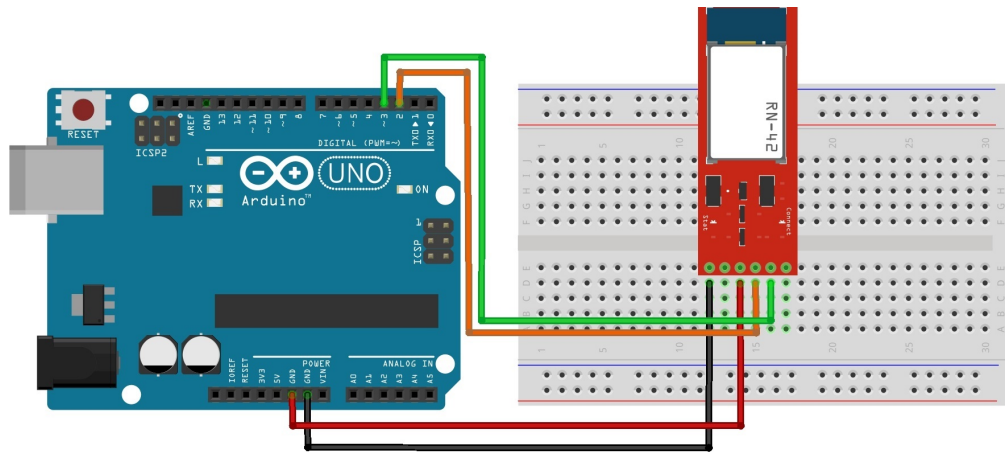


Figura 5.4: Conexión del módulo Bluetooth a la placa de adquisición y procesamiento de datos.

Para realizar la medida del consumo se utilizará el módulo INA219 de *Adafruit*³ que permite realizar lecturas de corriente y potencia. Se comunica con Arduino mediante el protocolo I2C. El módulo tiene una precisión de 0,1 mA.




Figura 5.5: Conexión del sensor de corriente a la placa de adquisición y procesamiento de datos.

El módulo Bluetooth y la placa Arduino UNO están alimentados mediante una batería de polímero de litio (LiPo) de 3.7V y 2000mAh que estando totalmente cargada siempre permite realizar los experimentos sin que la eficiencia de la batería llegue a un punto no lineal. Para la conexión del módulo INA219 únicamente se conecta el cable de Vin. El resto de cables están conectados a una placa Arduino Mini que será la encargada de recoger las lecturas del sensor de corriente y enviarlas. Se conectará al ordenador mediante un módulo FTDI con el que enviar los resultados obtenidos al puerto serie. Arduino UNO simulará el muestreo de la señal para aplicarle uno de los tres algoritmos vistos en el Capítulo 4 y después realizar el envío mediante el módulo Bluetooth.

Las conexiones entre las placas y los módulos son las siguientes:

³<https://www.adafruit.com/>




Figura 5.6: Conexiones del módulo Bluetooth y el sensor de corriente con la placa placa de adquisición y procesamiento de datos y Arduino Mini como dispositivo sonda.

Una vez conectados todos los módulos necesarios a las dos placas, se procederá a realizar las medidas de consumo. En primer lugar, se realizarán medidas sin cargar ningún código en la placa, para observar cuál es el consumo base del dispositivo. Después se pasará a medir el consumo de la implementación actual. Estas mediciones se realizarán igual en cada uno de los experimentos, y se realizará de la siguiente manera:

1. Lectura de la señal durante 1 minuto.
2. Tras la adquisición de muestras se realizará el procesado correspondiente a cada algoritmo de ese bloque de datos.
3. Una vez transcurrido 1 minuto de recepción de datos y se haya realizado el procesamiento completo, se enviarán todos los coeficientes obtenidos del procesamiento.

A efectos de representación, en el experimento diseñado se ha considerado una tasa de envío entre el microcontrolador y el Bluetooth de 9600 baudios. En el siguiente capítulo se expondrá con más detalle el procedimiento realizado para cada uno de los algoritmos estudiados.

Capítulo 6

Resultados

En el Capítulo 4 se explicó cómo se realizaban los bucles de optimización para las señales. A continuación, se explicará cuáles fueron los resultados obtenidos en el estudio previo y en las mediciones de consumo con las diferentes implementaciones.

Las Figuras 6.1a y 6.1b representan las señales de ECG y PPG respectivamente. El estudio está centrado sobre ambas señales.




Figura 6.1: Señales ECG y PPG obtenidas de los pacientes antes de aplicar las transformaciones.

Las señales ECG y PPG utilizadas para el estudio se han obtenido de diferentes pacientes. El ECG está muestreado a una frecuencia de 250Hz y el PPG a 75 Hz.

6.1. Métricas

En esta sección se expondrán las métricas y valores obtenidos para cada uno de los tres métodos explicados en el Capítulo 4. Para elegir los valores adecuados siempre se ha tenido como referencia el *fit* entre el HR original y el \widehat{HR} (reconstruido), además de la cantidad de datos que se pueden ahorrar en el envío.




Figura 6.2: Estructura de las señales ECG y PPG, donde se puede observar los picos *R* y los puntos sistólicos, que son los necesarios para calcular el HR.

Como se puede observar en la Figura 6.2a y la Figura 6.2b los picos *R* y los puntos sistólicos son los que tienen una mayor energía. Para el cálculo del HR se necesita medir la distancia entre picos *R* de la señal ECG y entre puntos sistólicos o diastólicos en el PPG. En este caso se medirán los puntos sistólicos. El resto de puntos no son necesarios para el cálculo del HR.




Figura 6.3: Gráfica sobre los diferentes componentes de la frecuencia del ECG y del PPG.

Como se puede comprobar en la Figura 6.3 parte del BW del ECG no contiene información relevante, por tanto únicamente necesitaremos una parte del ancho total del BW. En el PPG también se centra la información en un BW concreto.

Basándose en estas cualidades de las señales, se ha realizado la optimización de cada una de las transformaciones para poder reducir la cantidad de datos a enviar necesarios para realizar la reconstrucción.

6.1.1. Transformada discreta de Wavelet

Una vez aplicada la DWT deseamos solamente obtener los picos R en el ECG y los puntos sistólicos en el PPG, por tanto en este bucle de optimización se utiliza un umbral para poder filtrar los datos que tengan un menor nivel de energía. El umbral fue variando desde $-0,2V$ a $0,2V$ con un incremento de $0,005V$ para el ECG y desde $0V$ hasta $0,015V$ con un incremento de $0,001V$ para el PPG. Estos valores de umbral fueron conseguidos previamente mediante el estudio de un gran número de datos de ECG y PPG proporcionados por un paciente.

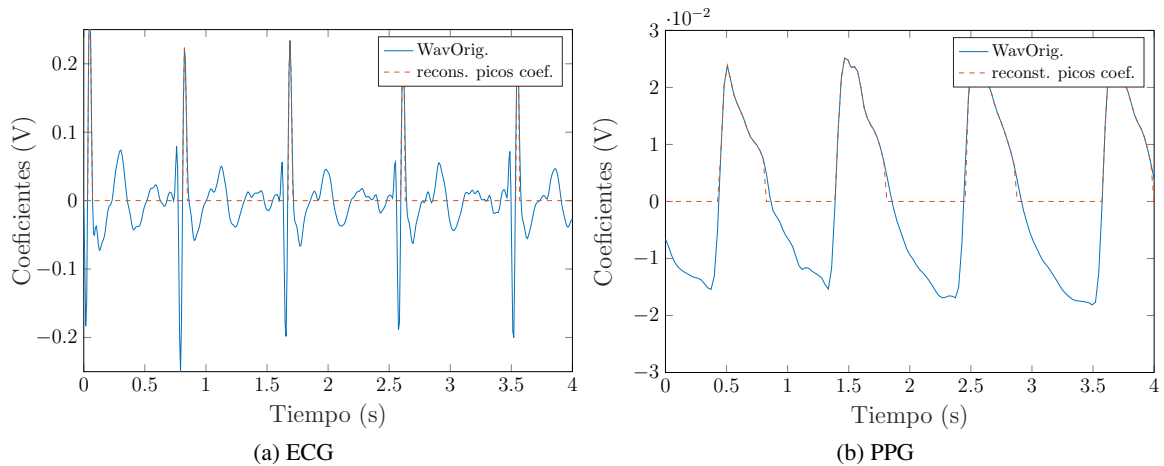


Figura 6.4: Coeficientes DWT originales vs coeficientes DWT filtrados. En esta grafica únicamente se muestran los datos de mayor energía (A). Los coeficientes de menor energía que el umbral seleccionado son despreciados.

En la Figura 6.4 se muestran los coeficientes de DWT originales frente a los obtenidos tras el bucle de optimización. Se puede ver que en la optimización se han puesto a cero todos los valores que estaban por debajo del umbral, dejando solo los valores de mayor energía con su valor original. El objetivo de poner los valores a cero es para posteriormente cuando se envíen los datos solamente mandar los que sean distintos a cero.

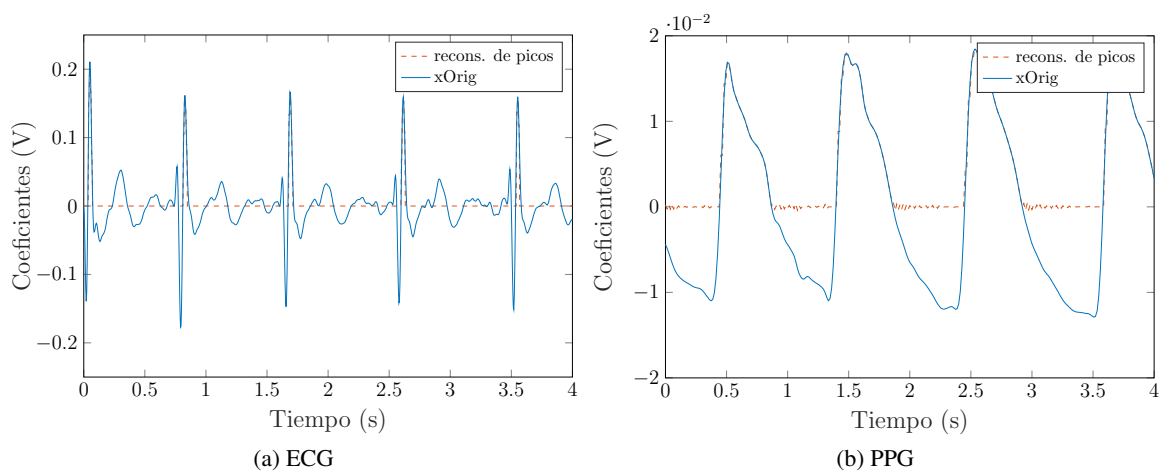


Figura 6.5: Reconstrucción de picos de las señales ECG y PPG respectivamente tras aplicar DWT.

En este método nuestro objetivo no es reconstruir la señal original, es conseguir una señal con la que calcular un \widehat{HR} lo más parecido al original. Aplicando la IDWT nos permite recuperar todos los valores cuyos coeficientes no fueran cero, y como se puede observar en la Figura 6.5, recuperamos los picos R y los puntos sistólicos necesarios para calcular el HR.

Tras esto pasamos a reconstruir el \widehat{HR} utilizando nuestra señal de picos R , para calcular el fit , que se obtiene comparando esta señal con la señal HR original calculada con la señal original sin modificar. Estos pasos se realizarán con cada uno de los posibles valores del umbral y así poder generar las gráficas necesarias para elegir cual es el valor que implementaremos posteriormente.




Figura 6.6: Relación entre el fit obtenido respecto al ahorro de muestras a enviar aplicando la DWT.

Se puede observar en la Figura 6.6a como hasta el 87 % de fit se necesita un número reducido de datos, pero a partir de ahí se necesita un aumento muy grande comparado al beneficio de porcentaje obtenido. Por tanto, el punto elegido para la implementación es el que se encuentra en el punto de inflexión de la curva. Para el PPG también se elegirá un fit similar.

Una vez elegido el fit comprobamos en la Figura 6.7 cuál es el valor de umbral que utilizaremos en la implementación.

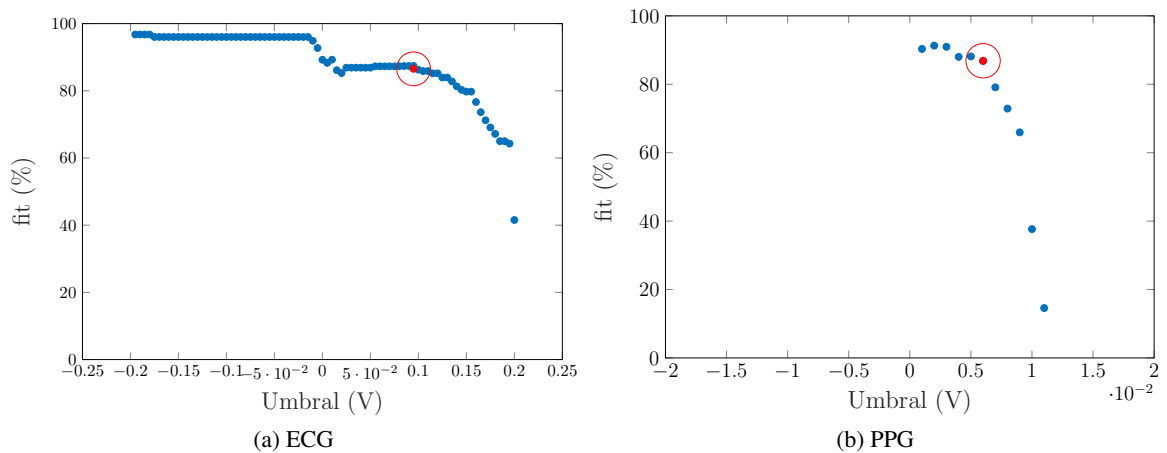


Figura 6.7: Relación entre el fit obtenido por cada uno de los umbrales del método de optimización de la DWT.

Los valores de umbral utilizados para la implementación serán de 0,095V para el ECG y 0,006V para el PPG.




Figura 6.8: Comparación entre el HR calculado con las señales originales y el \widehat{HR} obtenido con la optimización de la DWT. El *fit* para ambas señales es del 87 %.

Como se puede observar en la Figura 6.8 el HR original y el \widehat{HR} tienen un gran parecido, su *fit* para ambas señales es entorno al 87 %. Así que, a pesar de reducir la cantidad de datos hasta un 93 % del total para el ECG y un 81 % para el PPG, nos permite reconstruir la señal con calidad suficiente.

6.1.2. Transformada discreta de Fourier

Después de aplicar la DFT tenemos los datos en el espectro de la frecuencia. Fijándonos en la Figura 6.3a se observa que no es necesario enviar todo el espectro de datos, y que, únicamente, se encuentra la información necesaria para el cálculo del HR en un BW concreto de todo el espectro.




Figura 6.9: Información sobre el BW de la señal ECG y PPG respectivamente obtenido tras aplicar la DFT.

Como se puede ver en la Figura 6.9 de todo el espectro del BW, únicamente, nos interesa los

datos situados entre 3 Hz y 25 Hz para el ECG y entre 1 Hz y 10 Hz para el PPG. Solo se han representado los semi-ejes positivos en la DWT, la información esta espejada, por tanto también se utilizará la información del -25 Hz al -3 Hz en el ECG y del -10 Hz al 1 Hz para el PPG.

Los BW comprobados en este bucle tendrán un ancho mínimo de 7Hz para el ECG ya que el bloque de información es, como poco, de ese tamaño. Para el PPG todos los bucles comenzaran en 1Hz ya que ahí es donde se encuentra la mayor parte de la información necesaria.

La señal de ECG ha sido previamente filtrada para eliminar componentes de altas frecuencias que aparecen por acoplamiento electromagnético (como la frecuencia de la señal de la red eléctrica de 50 Hz). La señal de PPG es una señal óptica y no se observan acoplamientos de este estilo y por ello no ha sido previamente filtrada. Su energía se concentra por debajo de los 10 Hz; los lóbulos que se observan a partir de ahí son efecto del truncamiento de la señal (actuando como un filtro rectangular ideal).

En el bucle, para cada uno de los BW se reconstruye la señal ECG y PPG aplicándole a los datos seleccionados la IDFT. En este caso como no se envían únicamente los picos *R* o los picos sistólicos, sí es una reconstrucción de la señal, y no una detección de picos como se hacía en la DWT.

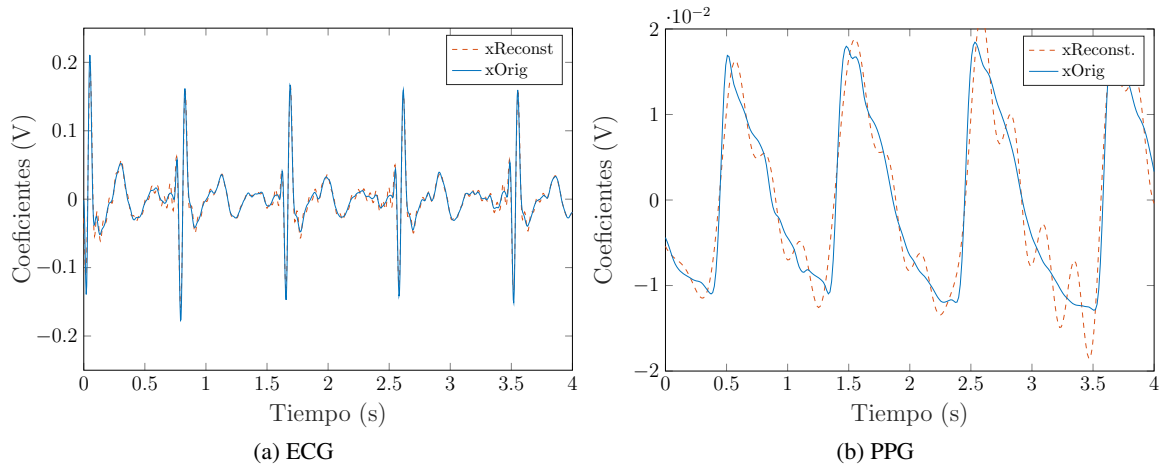


Figura 6.10: Señal ECG y PPG reconstruida tras aplicar el método de optimización DFT.

A pesar de reducir el espectro de frecuencia se puede observar en la Figura 6.10 que se consigue un gran parecido con la original. Con cada uno de los BW comprobados se genera una gráfica para nuevamente elegir cuál es el espectro de la frecuencia que vamos a implementar después.

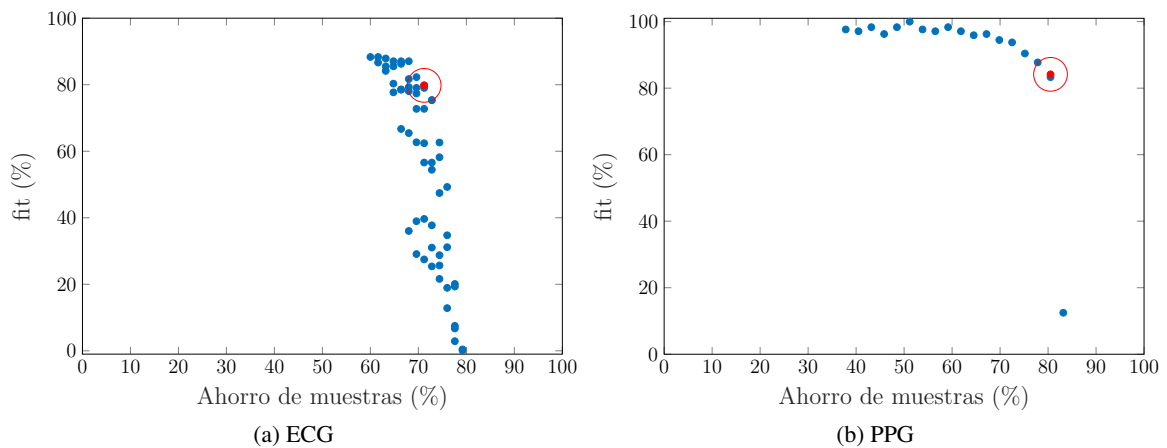


Figura 6.11: Porcentaje de ahorro obtenido para cada uno de los BW tras aplicar DFT.

Se observa en la Figura 6.11 una gran diferencia de puntos entre la señal ECG y la PPG. Esto se debe a que como el BW con información importante para el cálculo del HR es mayor para el ECG que para el PPG, se ha necesitado comprobar mayor cantidad de BW.

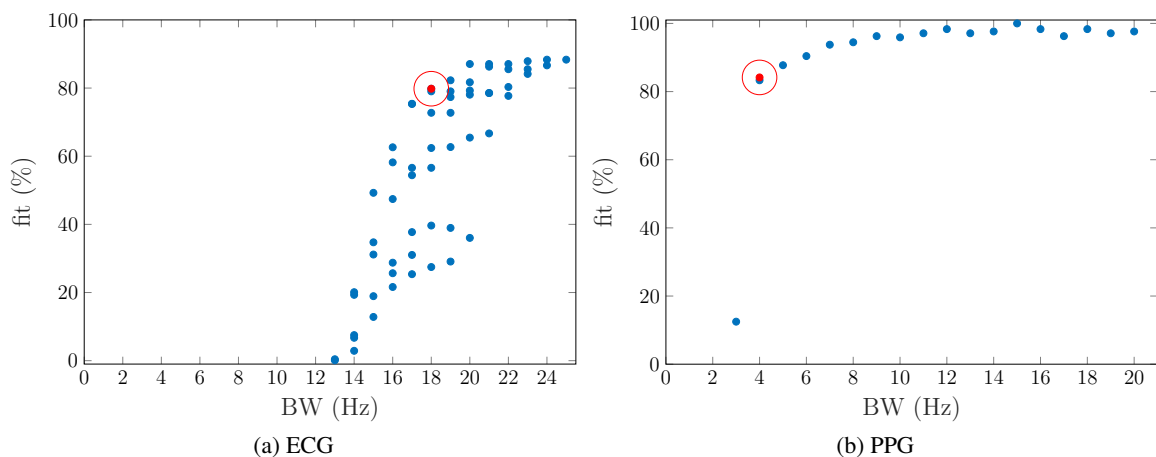


Figura 6.12: Comparación del *fit* obtenido por cada uno de los BW tras aplicar DFT.

En la Figura 6.12 se observa como al aumentar el BW se va aumentando el *fit* obtenido. A partir de 18Hz de BW se produce un aumento menor del *fit* por cada aumento en el espectro del ECG, por tanto ese será el punto elegido que se implementará. El BW utilizado comienza en 3Hz y termina en 21Hz. Para el PPG se observa como se produce un incremento mínimo para el ahorro de muestras, por tanto, el punto elegido es 4Hz, comenzando el BW en 0Hz y terminando en 4Hz.




Figura 6.13: Comparación entre el HR calculado con las señales originales y el \widehat{HR} obtenido con las señales reconstruidas tras aplicar DFT. El *fit* obtenido con la señal ECG es de 79 % y para el PPG es de 87 %.

En la Figura 6.13 se puede ver la comparación entre el HR original y el \widehat{HR} mediante la DFT. A pesar de haber un gran parecido en la señal, en el ECG se obtiene un 79 % de *fit* debido a que no reconoce bien los cambios bruscos. En el PPG el *fit* ha sido ligeramente superior, llegando hasta un 83 %. El ahorro conseguido para el ECG es de hasta un 71 % y del 81 % para el PPG.

6.1.3. Compressed Sensing

En este método el tamaño de señal utilizado es de 50 datos, así el tamaño de la matriz *sensing* utilizada es de 50x50, ya que si fuese mayor ocuparía demasiado en memoria. Se realizará un bucle sobre el ratio de compresión, *cr*, para comprobar cómo afecta la reducción con el *fit*. Esta reducción del *cr* implica disminuir la primera componente de la matriz *sensing*, *q*, que tomará valores en el bucle entre 1 y 50. Para calcular el vector *y*, que serán los datos que se envíen al coordinador, se debe realizar una multiplicación entre la matriz *sensing* y *x*, la señal adquirida. Debido a las propiedades de las matrices, los datos para enviar serán un vector de tamaño *q*.

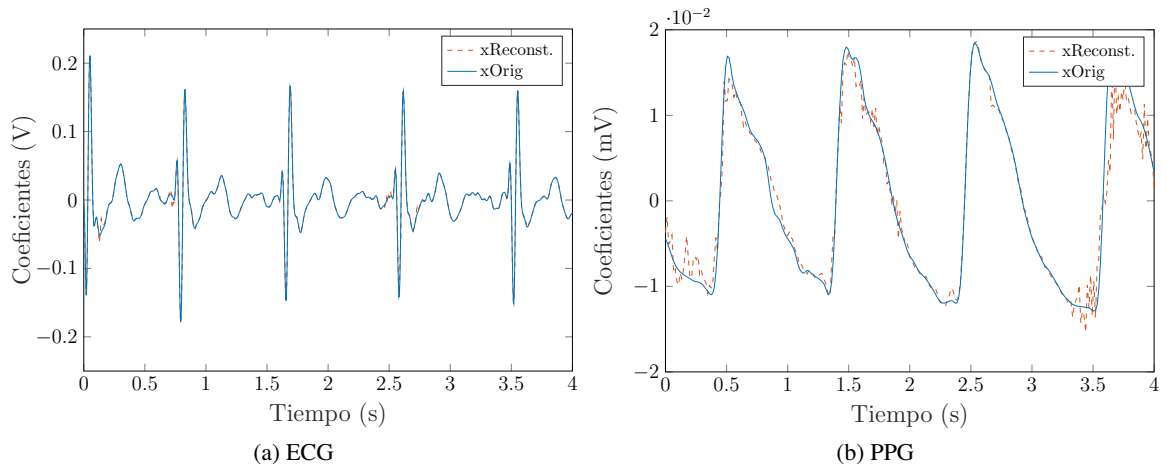


Figura 6.14: Señal ECG y PPG reconstruida tras aplicar CS.

Para cada una de las iteraciones del bucle se reconstruye la señal original. En la Figura 6.14a se puede ver cómo se obtiene un gran parecido en la señal, ya que este método reconstruye la señal entera en vez de únicamente las partes en las que hay información importante como ocurre en la DWT. Después de recuperar la señal, se genera el \widehat{HR} y se procede a calcular el *fit* respecto al HR de la señal original.

Tras obtener el *fit* de cada una de las iteraciones del bucle, se procede a generar las gráficas para obtener los valores finales del *cr* que serán utilizados en la implementación.

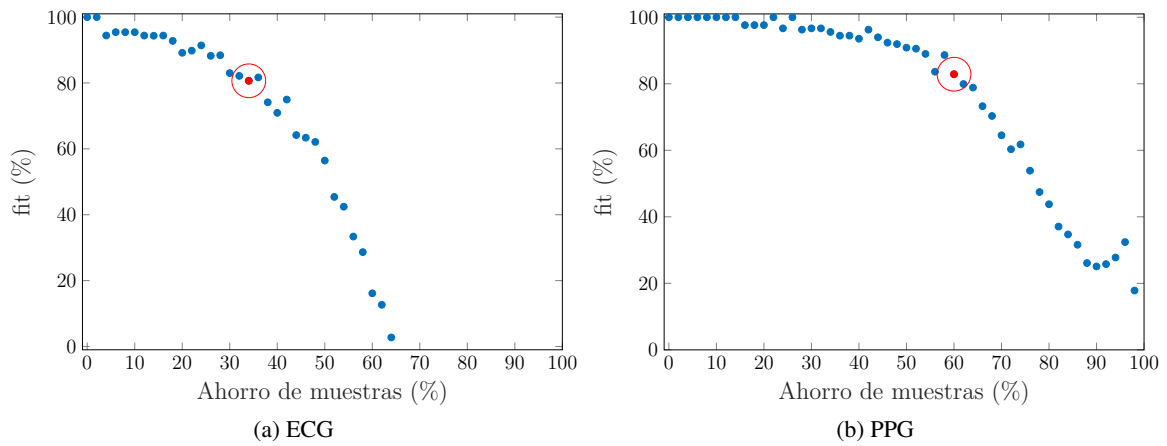


Figura 6.15: Relación del *fit* obtenido respecto al ahorro de muestras en la señal tras aplicar CS.

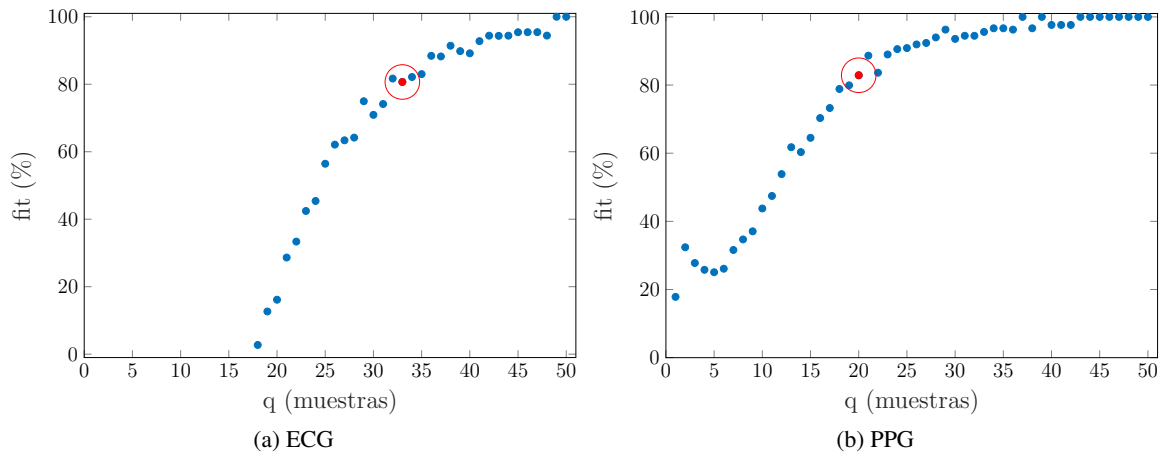


Figura 6.16: Valores del *fit* obtenidos respecto al número de muestras enviadas.

En este caso se utilizará un valor de 33 para q en la señal ECG, obteniendo un *fit* del 81 % y un ahorro del 34 %. Para el PPG se ha usado un valor de 20 q y se ha obtenido hasta un 82 % de *fit* para PPG, y un ahorro del 60 %. Los puntos han sido seleccionados tomando un valor de *fit* similar al resto de métodos, pero además teniendo en cuenta el ahorro de muestras.




Figura 6.17: Comparación HR vs \widehat{HR} . El *fit* obtenido para la señal con la señal ECG es del 81 % y del 82 % para la señal PPG.

6.2. Consumo energético

En esta sección se presentan los resultados obtenidos tras medir los consumos de cada uno de los métodos de optimización vistos.

El funcionamiento inicial de la aplicación consiste en adquirir datos durante un minuto e ir almacenándolos en un buffer para, una vez transcurrido este tiempo, enviarlos al servidor o equipo intermedio (*smartphone*), repitiendo este proceso continuamente. Que sea de un minuto la recepción se debe a la aplicación para la predicción de migrañas, que realiza las predicciones con resolución temporal de 1 minuto. En el estudio este será el *baseline* frente al que se compararán los tres métodos de optimización estudiados.

En la Sección 6.1 se extrajeron las métricas necesarias para la implementación de cada uno de los algoritmos. Para cada una de ellas se simulará la recepción de datos, el procesamiento de éstos y el envío mediante Bluetooth de los datos comprimidos. La adquisición de datos se realizará durante un minuto, y serán procesados según se van leyendo. Una vez transcurrido el minuto y haber aplicado el algoritmo de optimización a todos los bloques de datos se procederá a realizar el envío de todos los datos comprimidos.

Tanto en el *baseline* como en las implementaciones propuestas, durante el tiempo de envío no se podrán leer datos, lo que implica pérdidas de información en la señal, dependiendo de la duración del envío que tenga cada uno de los algoritmos. Otra opción es posponer el envío si los datos no son necesarios al momento, evitando así esta pérdida de información en la señal.

Se recuerda al lector, que a efectos de representación, en el experimento diseñado se ha considerado una tasa de envío entre el microcontrolador y el Bluetooth de 9600 baudios. Obsérvese que los valores absolutos mostrados son consecuencia exclusiva de este montaje experimental. No obstante el ahorro y los tiempos adquiridos mantienen la proporción, como se mostrará en este capítulo.




Figura 6.18: Medida del consumo del *baseline* para el ECG y el PPG.

El consumo del *baseline* se puede ver en la Figura 6.18. Los niveles más bajos de potencia son las fases de adquisición de datos, que se realizan durante 1 minuto. Los picos observados durante la fase de lectura se deben al modo sleep del Bluetooth, que cada 20 segundos se despierta para comprobar si dispone de datos que enviar, en nuestro caso. Tras esto se envían todos los datos leídos durante este minuto sin ningún tipo de procesamiento. Esta fase de envío mediante Bluetooth es el bloque de mayor energía que se puede observar en la Figura 6.18.

Consumo	ε_{ECG} (J)	ε_{PPG} (J)
Base dispositivo	1,657	1,657
Base + BT sin enviar datos	2,215	2,215
Base + BT enviando datos	15,184	7,573

Cuadro 6.1: Medidas de consumo del caso *baseline* de las señales ECG y PPG para el experimento diseñado.

En el Cuadro 6.1 se puede ver cómo se produce un aumento en el consumo cuando se realiza el envío de los datos. Para reducir el consumo en el dispositivo trataremos de reducir el tiempo de envío para que sea el menor posible. Todas las medidas de consumo que se mostrarán a continuación de cada uno de los algoritmos se realizan en el periodo de recepción de datos de 1 minuto, además del tiempo de procesamiento y envío de los datos obtenidos durante ese minuto.

6.2.1. Transformada discreta de Wavelet

En esta implementación se utilizó un valor de umbral de 0,095V para la ECG y 0,006V para el PPG. Con cada segundo de datos leído se aplica la DWT, y se filtran los datos respecto al umbral para desechar los datos que no son necesarios. Cada valor no nulo y la posición de este coeficiente en su array se almacena en un vector. Es necesario también enviar la posición en la que se encontraban para que, cuando se realice la reconstrucción, sepamos el lugar exacto de cada coeficiente, ya que para el cálculo del HR se necesita saber la distancia entre éstos.




Figura 6.19: Medida del consumo del método de optimización DWT para el ECG y el PPG.

Consumo	ε_{ECG} (J)	ε_{PPG} (J)
Base + procesamiento	1,738	1,769
Base + procesamiento + BT sin enviar datos	2,297	2,329
Base + procesamiento + BT enviando datos	3,665	3,658

Cuadro 6.2: Medidas de consumo aplicando DWT a la señal ECG y PPG para el experimento diseñado.

Utilizando el método de compresión basado en DWT se han obtenido resultados similares para ambas señales, ya que las dos permiten utilizar la técnica basada en umbral para únicamente seleccionar los picos.

6.2.2. Transformada discreta de Fourier

Para la implementación de este algoritmo se utilizó un BW de 18Hz, siendo 3Hz el inicio y 21Hz el final. En la señal PPG el BW comienza en 0Hz y termina en 4Hz (ver punto seleccionado en la Figura 6.12). Por cada bloque de 1 segundo se aplica la DFT a esos datos y se seleccionan únicamente los que pertenezcan al BW seleccionado. Pasado 1 minuto se envían todos los coeficientes seleccionados. Los coeficientes tras aplicar DFT tienen parte real y parte imaginaria, por lo que se deben enviar ambos. No es necesario indicar en qué posición se encontraba debido a que se sabe de antemano cuál va a ser el BW utilizado, entonces siempre la información va a estar en la misma posición.




Figura 6.20: Medida del consumo del método de optimización DFT para el ECG y el PPG.

Consumo	ε_{ECG} (J)	ε_{PPG} (J)
Base + procesamiento	1,783	1,761
Base + procesamiento + BT sin enviar datos	2,355	2,321
Base + procesamiento + BT enviando datos	6,596	3,433

Cuadro 6.3: Medidas de consumo aplicando DFT a la señal ECG y PPG para el experimento diseñado.

Por el contrario con el método basado en DFT se han obtenido mejores resultados con la señal PPG, ya que el BW que contiene la información relevante es menor que en el ECG, por tanto se ha podido reducir más la cantidad de datos a enviar.

6.2.3. Compressed Sensing

Tras aplicar CS a ambas señales, el *cr* utilizado es del 34 % para el ECG y del 60 % para el PPG, que corresponde a un valor de *q* de 33 y 20 respectivamente. Cada bloque leído se divide en vectores de 33 datos para el ECG y de 20 para el PPG (ver Sección 4.4), que suponen 0,13 segundos para el ECG y 0,26 para el PPG. Seguidamente se realiza la multiplicación entre la matriz *sensing* y el vector de la señal. Como resultado se obtiene el vector *y*, cuya longitud es 33 en el ECG y 20 para el PPG, que se ira almacenando durante 60 segundos. Pasado este tiempo se enviaran los coeficientes obtenidos.




Figura 6.21: Medidas del consumo del método de optimización CS para el ECG y el PPG.

Consumo	ε_{ECG} (J)	ε_{PPG} (J)
Base + procesamiento	2,069	1,873
Base + procesamiento + BT sin enviar datos	2,653	2,402
Base + procesamiento + BT enviando datos	11,749	4,795

Cuadro 6.4: Medidas del consumo aplicando CS a la señal ECG y PPG para el experimento diseñado.

Utilizando el método de optimización CS se puede observar como se han obtenido mejores resultados con la señal PPG. Esto se debe a que la señal ECG tiene una mayor variabilidad, que se puede ver tanto en su forma de onda como en su espectro (tiene información en más altas frecuencias).

6.2.4. Comparativa de consumos

Debido a que la frecuencia de muestreo del PPG es menor a la del ECG, la cantidad de datos generados es un 70 % menos, con la consiguiente reducción de tiempo de envío que implica, que se observa en los Cuadro 6.5 y Cuadro 6.6.

	Base.	DWT	DFT	CS
Procesamiento	0	1	13	20
Envío Coeficientes	4779	147	967	2477
Total	4779	148	980	2497

Cuadro 6.5: Comparación del consumo (mJ) de los algoritmos de compresión para la señal ECG

	<i>Base.</i>	DWT	DFT	CS
Procesamiento	0	1	1	6
Envío Coeficientes	1467	115	108	449
Total	1467	116	109	455

Cuadro 6.6: Comparación del consumo (mJ) de los algoritmos de compresión para la señal PPG.

Para la señal ECG se puede ver en el Cuadro 6.5 que el método de compresión basado en DWT ha ofrecido mejores resultados que el resto, pero en cambio para la señal PPG se puede comprobar en el Cuadro 6.6 que los métodos de compresión que mejores resultados han dado han sido los basados en DFT y en DWT. Estas diferencias se deben a las propiedades de las señales utilizadas (BW de la información, repetitividad, morfología...), por lo tanto los resultados obtenidos con cada uno de los métodos de compresión utilizados dependerá de las propiedades de la señal que se utilice; así, si en el estudio de migrañas se desea aplicar estas técnicas sobre otras señales (encefalograma, acelerometría...) las conclusiones obtenidas serán distintas.

Observando los resultados obtenidos en las mediciones, se puede concluir que el consumo y tiempo por procesamiento son despreciables respecto al tiempo y consumo del envío, ya que el procesamiento supone aproximadamente el 1 % del consumo total de cada algoritmo de optimización.

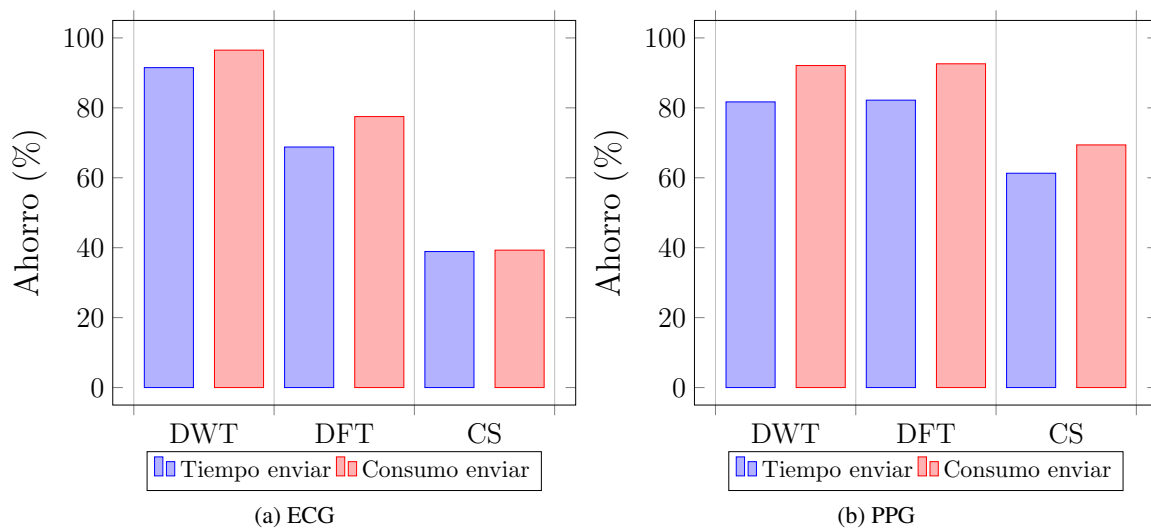


Figura 6.22: Comparación del porcentaje consumo que supone el envío y el procesamiento de los datos en cada uno de los algoritmos.

Se puede observar en la Figura 6.22 en qué porcentaje se ha reducido el tiempo de envío y el consumo de enviar los coeficientes. Para la señal ECG se puede observar que los mejores resultados fueron obtenidos con el método de optimización basado en DWT, ahorrando hasta un 93,2 % en el tiempo de envío y hasta un 96,5 % en el consumo de enviar los datos. En cambio, para el PPG los resultados obtenidos con los métodos de optimización basado en DWT y en DFT han sido muy similares, pero siendo superiores en la DFT, consiguiendo un ahorro de hasta el 82.2 % en el tiempo de envío y hasta un 92.6 % en el consumo de enviar los datos. Esto reducirá el tiempo

que necesita estar en *idle* para enviar los datos. En este estudio se ha realizado el envío una vez se han ido calculando los parámetros de los algoritmos. Estos resultados son específicos de los valores elegidos y deferirán según se elijan los parámetros: sacrificando consumo, o sacrificando calidad.

También, viendo los resultados obtenidos, se podría en una implementación real eliminar el sensor de ECG, con todo lo que ello conlleva: comodidad, reducción de los datos generados, menor coste y mayor ahorro de consumo.

En este estudio se ha demostrado que utilizando cualquiera de las técnicas de optimización vistas se ha conseguido una reducción en el tiempo de envío y en el consumo. Con esta reducción se conseguirá una mejor experiencia para el usuario en el estudio, ya que necesitará realizar un menor número de cargas y podrá estar un mayor tiempo monitorizando de forma continua, lo que implica una reducción de pérdidas de datos provocadas por cortes en el dispositivo debido al agotamiento de la batería.

Capítulo 7

Conclusiones

Las WBSNs se utilizan en la monitorización continua ambulatoria. Estas redes trabajan de forma autónoma mediante baterías y, para aumentar su autonomía, es importante reducir el consumo de energía. En este TFG este problema se aborda mediante el uso de técnicas de compresión de datos para reducir la cantidad de datos enviados y, por tanto, el consumo de energía debido a la transmisión. Utilizando técnicas de compresión basadas en la transformada de Wavelet, la transformada de Fourier y en Compressed Sensing se ha conseguido reducir considerablemente la cantidad de datos enviados, permitiendo reconstruir la señal con ajustes de reconstrucción de hasta un 87 %. Se ha demostrado en una implementación en un dispositivo real que el tiempo de cómputo en cada una de ellas es prácticamente despreciable en comparación con el ahorro de tiempo de envío. Se han aplicado las tres técnicas sobre señales con una alta densidad de muestras (electrocardiograma y fotopletimografía). Para el electrocardiograma se han obtenido los mejores resultados con el método de compresión basado en DWT, consiguiendo ahorros de hasta un 93 %, teniendo un ajuste de reconstrucción del 87 %. Para la señal PPG el que mejor resultados ha ofrecido ha sido el basado en DFT, permitiendo ahorrar un 87 % del total de los datos, teniendo un ajuste de reconstrucción del 87 %. Sacrificando el porcentaje de ahorro se pueden obtener mejores ajustes. Se ha realizado un estudio detallado, que relaciona el porcentaje y el ajuste. Se puede concluir que las tres técnicas consiguen reducir el tamaño total de datos, y que los resultados obtenidos dependerán de las propiedades de la señal usada y el nivel de similitud necesaria al reconstruir los datos. Este proyecto se enmarca en un estudio de investigación de la predicción de la migraña mediante monitorización continua ambulatoria mediante WBSNs. Gracias a esta reducción de consumo se podrá mejorar la experiencia de usuario en el estudio, ya que se reducirán las pérdidas de datos provocadas por cortes, pudiendo estar un mayor tiempo monitorizando de forma continua.

Conclusions

WBSNs are used in ambulatory continuous monitoring. These networks work autonomously using batteries and, to increase their autonomy it is important to reduce the energy consumption. In this TFG this problem is tackled through the use of data compression techniques to reduce the amount of data sent and thus the energy consumption due to transmission. Using compression techniques such as the Wavelet transform, the Fourier transform and Compressed Sensing, the amount of data wirelessly transmitted has been considerably reduced, allowing the reconstruction of biomedic signals with up to 87 % accuracy. It has been demonstrated in an implementation in a real device that the computation time in each of the compression techniques is almost negligible compared to the savings of sending time. The three compression techniques were applied in biomedic signals with a high sample density (electrocardiogram and photoplethysmography). For the electrocardiogram the best results were obtained with the DWT based compression method, achieving savings of up to 93 %, having a reconstruction adjustment of 87 %. For PPG signal the best results have been the DFT based, allowing to save 87 % of the total data, having a reconstruction adjustment of 87 %. It is possible to increase these accuracies by sacrificing savings, and a detailed study of this trade-off has also been carried out. It can be concluded that the three techniques can reduce the total data size, and that the results obtained will depend on the properties of the signal used and the level of similarity required when reconstructing the data. This TFG is framed in a research study of migraine prediction by ambulatory continuous monitorization using WBSNs. Thanks to the energy savings achieved, the user experience of people that collaborate in this study can be improved, as it will reduce data loss by increasing the battery life, and will allow longer periods of monitorization without disruptions.

Capítulo 8

Futuras Líneas de Investigación

En lugar de realizar las implementaciones sobre una placa Arduino, sería más interesante poder realizar las implementaciones en algún dispositivo médico equipado con sensores para poder recibir señales en tiempo real. Este estudio ha dejado diferentes líneas por las que se puede continuar la investigación, se nombraran las más importantes a continuación:

- Aplicar técnicas de detección de falsos picos o picos no detectados.
- Incluir en los objetivos de optimización la métrica utilizada en el proyecto de predicción de migrañas.
- Utilización de técnicas de optimización más avanzadas
- Incluir otras métricas diferentes al *fit* para la comparación de señales

Bibliografía

- [1] X. H. Hu, N. H. Raskin, R. Cowan, L. E. Markson, and M. L. Berger, “Treatment of migraine with rizatriptan: when to take the medication,” *Headache: The Journal of Head and Face Pain*, vol. 42, no. 1, pp. 16–20, 2002.
- [2] M. Linde, A. Gustavsson, L. Stovner, T. Steiner, J. Barré, Z. Katsarava, J. Lainez, C. Lampl, M. Lantéri-Minet, D. Rastenyte, *et al.*, “The cost of headache disorders in europe: the euro-light project,” *European journal of neurology*, vol. 19, no. 5, pp. 703–711, 2012.
- [3] J. Pagán, D. Orbe, M. Irene, A. Gago, M. Sobrado, J. L. Risco-Martín, J. V. Mora, J. M. Moya, and J. L. Ayala, “Robust and accurate modeling approaches for migraine per-patient prediction from ambulatory data,” *Sensors*, vol. 15, no. 7, pp. 15419–15442, 2015.
- [4] J. Klucken, J. Barth, P. Kugler, J. Schlachetzki, T. Henze, F. Marxreiter, Z. Kohl, R. Steidl, J. Hornegger, B. Eskofier, *et al.*, “Unbiased and mobile gait analysis detects motor impairment in parkinson’s disease,” *PloS one*, vol. 8, no. 2, p. e56956, 2013.
- [5] B. E. Heldberg, T. Kautz, H. Leutheuser, R. Hopfengärtner, B. S. Kasper, and B. M. Eskofier, “Using wearable sensors for semiology-independent seizure detection-towards ambulatory monitoring of epilepsy,” in *Engineering in medicine and biology society (EMBC), 2015 37th annual international conference of the IEEE*, pp. 5593–5596, IEEE, 2015.
- [6] L. Schwiebert, S. K. Gupta, and J. Weinmann, “Research challenges in wireless networks of biomedical sensors,” in *Proceedings of the 7th annual international conference on Mobile computing and networking*, pp. 151–165, ACM, 2001.
- [7] F. Rincón, J. Recas, N. Khaled, and D. Atienza, “Development and evaluation of multi-lead wavelet-based ecg delineation algorithms for embedded wireless sensor nodes,” *IEEE Transactions on Information Technology in Biomedicine*, vol. 15, no. 6, pp. 854–863, 2011.
- [8] O. Faust, U. R. Acharya, J. Ma, L. C. Min, and T. Tamura, “Compressed sampling for heart rate monitoring,” *Computer methods and programs in biomedicine*, vol. 108, no. 3, pp. 1191–1198, 2012.
- [9] R. M. Seepers, C. Strydis, P. Peris-Lopez, I. Sourdis, and C. I. De Zeeuw, “Peak misdetection in heart-beat-based security: Characterization and tolerance,” in *Engineering in Medicine and Biology Society (EMBC), 2014 36th Annual International Conference of the IEEE*, pp. 5401–5405, IEEE, 2014.

- [10] R. M. Seepers, J. H. Weber, Z. Erkin, I. Sourdis, and C. Strydis, “Secure key-exchange protocol for implants using heartbeats,” in *Proceedings of the ACM International Conference on Computing Frontiers*, pp. 119–126, ACM, 2016.
- [11] B. Furht, ed., *Discrete Wavelet Transform (DWT)*, pp. 188–188. Boston, MA: Springer US, 2008.
- [12] B. K. Natarajan, “Sparse approximate solutions to linear systems,” *SIAM journal on computing*, vol. 24, no. 2, pp. 227–234, 1995.
- [13] J. Pagán, M. Zapater, and J. L. Ayala, “Power transmission and workload balancing policies in ehealth mobile cloud computing scenarios,” *Future Generation Computer Systems*, 2017.

Autorización de difusión

Autorización para la difusión del Trabajo Fin de Grado y su depósito en el Repositorio Institucional E-Prints Complutense

Los abajo firmantes, alumno y tutor del Trabajo Fin de Grado (TFG) en Ingeniería de Computadores de la Facultad de Informática, autorizan a la Universidad Complutense de Madrid (UCM) a difundir y utilizar con fines académicos, no comerciales y mencionando expresamente a su autor, el Trabajo Fin de Grado (TFG) cuyos datos se detallan a continuación. Así mismo autorizan a la Universidad Complutense de Madrid a que sea depositado en acceso abierto en el repositorio institucional con el objeto de incrementar la difusión, uso e impacto del TFG en Internet y garantizar su preservación y acceso a largo plazo.

TÍTULO del TFG: **Implementación de técnicas de bajo consumo en WBSN.**

Curso académico: 2016/2017

Nombre del Alumno: **Álvaro Martín Otero.**

Tutor del TFG: **José Luis Ayala Rodrigo**

Josué Pagán Ortiz, Departamento de Arquitectura de Computadores y Automática.

Firma del alumno

Firma del tutor